

ŠUMARSKI FAKULTET SVEUČILIŠTA U ZAGREBU

ŠUMARSKI ODSJEK

SVEUČILIŠNI DIPLOMSKI STUDIJ

URBANO ŠUMARSTVO, ZAŠTITA PRIRODE I OKOLIŠA

MAGDALENA MARAČIĆ

**AKTIVNOST DIVLJAČI NA LOKALITETU ROV
JUŽNOG DIJELA MEDVEDNICE**

DIPLOMSKI RAD

ZAGREB, 2017.

ŠUMARSKI FAKULTET SVEUČILIŠTA U ZAGREBU

ŠUMARSKI ODSJEK

**AKTIVNOST DIVLJAČI NA LOKALITETU ROV JUŽNOG
DIJELA MEDVEDNICE**

DIPLOMSKI RAD

Diplomski studij: Urbano šumarstvo, zaštita prirode i okoliša

Predmet: Gospodarenje životinjskim vrstama

Ispitno povjerenstvo:

- 1. Prof. dr. sc. Krešimir Krapinec**
- 2. Prof. dr. sc. Marijan Grubešić**
- 3. Dr. sc. Kristijan Tomljanović**
- 4. Prof. dr. sc. Josip Margaletić**

Student: Magdalena Maračić

JMBAG: 0068206483

Broj indeksa: 712/2015

Datum odobrenja teme: 20. 04. 2017.

Datum predaje rada: 15. 09. 2017.

Datum obrane rada: 22. 09. 2017.

Zagreb, rujan 2017.

PREDGOVOR

Ovaj rad je izrađen u sklopu projekata „**Primijenjena istraživanja divljači na području Parka prirode 'Medvednica' – Grad Zagreb**“, kojeg provodi Šumarski fakultet Sveučilišta u Zagrebu te „**Zdravlje divljači i zoonotski potencijal na području Parka prirode 'Medvednica' – Grad Zagreb**“, stoga zahvaljujem Gradskom uredu Grada Zagreba na razumijevanju koje su pokazali glede potrebe provođenja projekta te na njegovu financiranju, osobito pročelniku Ureda gospodinu **Emilu Tuku**, dr. vet. med., te njegovim suradnicima gospodinu **Danku Hermanu**, dipl. ing. šum. i **Mati Barbiru**, dipl. iur.

Zahvaljujem lovcima, članovima LU „Prepelica“ Sesvete, osobitu Ranku Ledinšćiću (predsjedniku) uz čiju pomoć je načinjena hvataljka za divlje svinje u kojoj je postavljena kamera za praćenje divljači te članovima Lovačke udruge, Ivanu Babiću i Mariju Pandeku, koji su obilazili lokalitet, donosili hranu za divljač u hvataljku te vodili brigu o postavljenoj kameri.

Također, veliko hvala roditeljima, suprugu i prijateljima na bezuvjetnoj podršci, te mentoru prof. dr. sc. Krešimiru Krapincu na savjetima, dobroj volji i nesebičnom trudu tijekom izrade ovog rada.

Dokumentacijska kartica

Naslov	Aktivnost divljači na lokalitetu Rov južnog dijela Medvednice
Title	Game activity on locality Rov, southern part of Medvednica
Autor	Magdalena Maračić
Adresa autora	Marice Barić 23, Zagreb
Mjesto izrade	Šumarski fakultet Sveučilišta u Zagrebu
Vrsta objave	Diplomski rad
Mentor	Prof. dr. sc. Krešimir Krapinec
Izradu rada pomogao	
Godina objave	2017.
Obujam	Broj stranica: 51; tablica: 4; slika: 34; navoda literature: 76
Ključne riječi	Daljinska kamera, aktivnost divljači, RAI-relativni indeks brojnosti, mjesečeve mijene, temperatura
Key words	Remote camera, game movement, RAI-relative abundance index, moon phases, temperature
Sažetak	<p>Utjecaj abiotičkih čimbenika na divlje životinje intenzivnije je istraživao od 40-tih godina 20. stoljeća na ovamo. Tada su počela istraživanja utjecaja mjesečevih mijena i mjesečine, na kretanje životinja, korištenje staništa te odnos predator-plijen. Međutim, zadnjih 20-tak godina u istraživanjima divljih životinja sve su češće u upotrebi tzv. „foto klopke“, odnosno digitalne kamere za praćenje životinja. U ovom diplomskom radu se pokušalo istražiti dali je na pojedinim lokalitetima samo jednom kamerom koja će biti aktivna dulje vrijeme moguće dobiti određene podatke o godišnjoj fluktuaciji u brojnosti divljači, aktivnosti divljači, spektru životinjskih vrsta na određenom lokalitetu te pojedine stanišne čimbenike koji utječu na spomenute parametre. Istraživanje je provedeno u jugoistočnom dijelu Parka prirode „Medvednica“, koje teritorijalno spada u Grad Zagreb, na lokalitetu „Rov“. Tijekom istraživanja razdoblja kamera je bila aktivna 14 038 sati i 42 minute, a pri tome je kamera snimila 1 799 snimaka, od čega 462 prazne snimke (snimke na kojima nije bilo snimljenih životinja), te 1 337 iskoristivih snimaka (snimke na kojima je bilo jedna ili više životinja). Na temelju dobivenih podataka izrađeni su grafikoni aktivnosti životinja s obzirom na mjesece, mjesečeve mijene i temperaturu zraka.</p>

IZJAVA O IZVORNOSTI DIPLOMSKOG RADA

„Izjavljujem da je moj diplomski rad izvorni rezultat mog rada te da se u izradi istoga nisam koristila drugim izvorima osim onih koji su u njemu navedeni.“

Magdalena Maračić

U Zagrebu, 22. rujna 2017.

SADRŽAJ

1. UVOD.....	1
2. CILJ ISTRAŽIVANJA	4
3. MATERIJAL I METODE	7
3.1. PODRUČJE ISTRAŽIVANJA	7
3.2. ZNAČAJKE KORIŠTENE KAMERE	9
3.3. OBRADA PODATAKA I STATISTIČKE ANALIZE	15
4. REZULTATI.....	19
4.1. GODIŠNJA DINAMIKA BROJA SNIMAKA TE RELATIVNI INDEKSI BROJNOSTI.....	19
4.2. DNEVNA AKTIVNOST DIVLJAČI TIJEKOM ISTRAŽIVANOG RAZDOBLJA	23
4.3. UTJECAJ MJESEČEVIH MIJENA NA AKTIVNOST DIVLJAČI.....	26
4.4. UTJECAJ TEMPERATURE ZRAKA NA AKTIVNOST DIVLJAČI.....	30
5. RASPRAVA.....	33
5.1. METODOLOGIJA OBRADE SNIMAKA DOBIVENIH KAMERAMA ZA PRAĆENJE DIVLJAČI	33
5.2. NAČIN POSTAVLJANJA KAMERA I UTJECAJ POLOŽAJA KAMERE NA REZULTATE PRAĆENJA DIVLJAČI.....	37
5.3. UTJECAJ POJEDINIH OKOLIŠNIH ČIMBENIKA NA PONAŠANJE ŽIVOTINJA	39
6. ZAKLJUČCI.....	45
7. LITERATURA	46

1. UVOD

Praćenje ponašanja životinja traje gotovo od kada je čovjek postao lovac. Međutim, zanimanje biologa u otkrivanju novih životinjskih vrsta, njihove rasprostranjenosti (nazočnost ili potencijalna odsutnost) te detaljno pronicanje u mehanizme njihova ponašanja (aktivnost, socijalno međudjelovanje, ishrana itd.) traje nekoliko stoljeća.

Utjecaj abiotičkih čimbenika na divlje životinje intenzivnije je istraživao od 40-tih godina 20. stoljeća na ovamo. Tada su počela istraživanja utjecaja mjesečevih mijena i mjesečine, na kretanje životinja, korištenje staništa te odnos predator-plijen. Međutim, zadnjih 20-tak godina u istraživanjima divljih životinja sve su češće u upotrebi tzv. „foto klopke“, odnosno digitalne kamere za praćenje životinja. Iako, tehnika korištenja foto pomagala u ovakvih istraživanjima ima svoju dulju povijest.

Kao službena godina početka korištenja kamera u istraživanju ptica može se uzeti 1956. (Cox i sur., 2012.). Tada su Gysel i Davis istraživali plijenidbu gnijezda goluba. Tri godine kasnije (1959.) Royama je objavio rad u kojem je snimao plijen koji velika sjenica (*Parus major*) drži kljunom. No, tijekom zadnjih 50 godina se ta tehnologija naglo razvila, a nakon što su razvijene kamere s infracrvenim senzorima, ova se tehnika istraživanja divljih životinja počela široko primjenjivati (McCoy i sur., 2011.).

Foto klopke su veliku primjenu postigle u ispitivanjima propusnosti autocesta (Clevenger i sur., 2013.) s time da se u takvim istraživanjima koristi dosta kamera tijekom dugog vremenskog razdoblja (nekoliko godina). Zbog toga se podaci prije interpretacije trebaju standardizirati. To se radi tako da se broj snimljenih životinja podijeli s brojem kamera (npr. 20 detektiranih jedinki/5 aktivnih kamera = 4 standardizirane detekcije životinja). Clevenger i sur. (2013.) su tijekom 6 godina praćenja propusnosti autoputa u Kanadi uočili kako se tijekom zime životinje gibaju manje nego tijekom ljeta. To je i logično jer se tijekom ljetnog razdoblja većina vrsta pari ili podiže mladunčad što zahtjeva veće kretanje, odnosno općenito veću mobilnost. Tako se aktivnost američkog crnog medvjeda (*Ursus americanus*), smeđeg medvjeda (*Ursus arctos*), sivog vuka (*Canis lupus*) i pume (*Felis concolor*) tijekom dana nije razlikovala, dok su sve vrste cervida i kojot (*Canis latrans*) pokazivali dnevnu dinamiku aktivnosti. Medvjedi i vukovi su pokazivali uglavnom krepuskularne (sumračne) i dnevne obrasce aktivnosti, a pume su uglavnom bile aktivne tijekom noći. Osim losa (*Alces alces*), koji je najaktivniji ujutro, ostale vrste cervida su bile najaktivnije ujutro i navečer.

Općenito, u istraživanju divljih životinja kamere se mogu koristiti za dobivanje snimaka koje će dati evidenciju o:

- ✓ nazočnosti (Jenks i sur., 2011.; Clevenger i sur., 2013.; Gregersen i Gregersen, 2014.);
- ✓ veličini populacije (Mccoy i sur., 2011.; Plhal i sur., 2011.; Šprem i sur., 2011.);
- ✓ obrascima ponašanja (Racheva i sur., 2012.; Prebanić, 2014.; Clevenger i sur., 2013.; Gregersen i Gregersen, 2014.);
- ✓ plijenidbi (O'Brien i sur., 2003.);
- ✓ kondiciji (Marshall i sur., 2008.) i
- ✓ hranidbenoj ekologiji pojedinih životinjskih vrsta (Otani, 2001., 2002.)

U ornitologiji se primjena ovih kamera pokazala vrlo praktičnom u istraživanjima:

- ✓ identificiranja predatora gnijezda (Pietz i Granfors, 2000.),
- ✓ strategije podizanja mladunčadi (Cartar i Montomerie, 1987.),
- ✓ identificiranja plijena (Spittler, 1995.) te
- ✓ ponašanja mladih tijekom gniježđenja (Nathan i sur., 2001.)

Osim toga, kamerama je moguće i zabilježiti iznimno rijetke oblike ponašanja kao što su kanibalizam jaja i ptica (Gilbert i sur., 2005.) ili pomoć u gniježđenju ne kooperativnih ptičjih vrsta (Guzy i sur., 2002.). Isprva su korištene kamere s analognim načinom snimanja, no u 2003., se već u 11 % istraživanja ptica s kamerama koriste digitalni zapisi, a u 2006. je taj udio porastao na 21 % (Cox i sur., 2012.). Pri tome je nužno istaknuti kako su 69 % sustava kamera istraživači načinili sami sklapajući sastavnice različitih proizvođača.

Sami sustavi snimanja su se također dosta razlikovali. Prema analizi Cox i sur. (2012.) u 327 znanstvenih članaka iz područja ornitologije u kome su istraživanja vršena pomoću kamera (foto klopki) u 38 % slučajeva je korištena tehnika snimanja protoka vremena, u 33 % slučajeva je korištena tehnika snimanja pomoću manualnih ili IC okidanja, a manje korištene tehnike su video snimke (8 %) koje su korištene uglavnom za istraživanje sadržaja gnijezda.

Rezimirajući pojedine radove i priručnike kamere se danas primjenjuju za istraživanja divljih životinja s različitim zadaćama:

1. Dokumentiranje nazočnosti neke vrste na nekom području – predstavlja najjednostavniji oblik korištenja foto klopki;
2. Istraživanje obrazaca aktivnosti i točno određenih aspekata ponašanja neke vrste;

3. Analiza prostornih obrazaca pojavnosti neke vrste – ovo je moguće načiniti ukoliko je poznata točna lokacija kamere;
4. Određivanje vjerojatnosti detekcije neke vrste – ukoliko se razdoblje kontinuiranog praćenja podijeli u posebna vremenska razdoblja koja simuliraju ponovljeno uzorkovanje na lokaciji svake kamere.
5. Kod onih vrsta koje je moguće razlučiti na razini jedinke (nose određene šare na pokrovu, rogovlje, obilježene su markicama itd.) snimke daju podatke o ponovljenoj individualnoj detekciji/ne detekciji radi primjene modela hvatanja-puštanja i ponovnog hvatanja. Na temelju tih modela je moguće izračunati brojnost i gustoću populacije.
6. Snimke pružaju izvorni materijal o vrsti što je idealno za prezentaciju njena stanja prema javnosti. Istodobno time raste i informacija o projektu ili ishodu zaštite.

Same kamere pokazuju svoje nedostatke i ograničenja. Naime, glede samih životinja treba istaknuti kako su one idealne za istraživanje srednje velikih životinjskih vrsta i to uglavnom onih koje se kreću po tlu (kod ptica su to uglavnom vrste iz reda kokoški). Sitne sisavce, kao što je većina glodavaca, kamere nisu u mogućnosti pouzdano detektirati, odnosno oni mogu lagano prolaziti kroz gusto raslinje te je vjerojatnost da će proći ispred kamera relativno mala. Isto tako je mala vjerojatnost detektiranja arborealnih (primati – Primates, puhovi – Gliridae, vjeverice – Sciuridae) i semiakvatičnih vrsta. Na uspjeh detekcije kamera utječe i samo stanište. Tako otvorena staništa poput travnjaka i močvara, čak i prizemnih slojeva šuma mogu predstavljati relativno malo područje nekog krajobraza preko kojeg je životinju moguće uočiti da se kreće, jasno ukoliko tamo nema uočljivih staza. U tim je slučajevima dosta teško odrediti mjesto postavljanja kamere jer se životinja često puta kreće iza kamere, odnosno izvan zone detekcije. U konačnici, foto klopke najbolje rade u suhim područjima. Ovo ne znači da ona neće raditi i u vlažnim klimatskim područjima, već joj je tada radni vijek znatno smanjen.

2. CILJ ISTRAŽIVANJA

S obzirom na sve višu stopu nestanka pojedinih životinjskih vrsta, na globalnoj razini, u suvremenim istraživanjima je postalo ne samo važno odrediti sastav vrsta na određenom području nego i dokučiti dinamiku populacija, odnosno procijeniti koliko jedinki živi na određenom području (veličina populacije) te da li populacija raste ili pada tijekom vremena – dinamika populacije ili trenutni trend. Stoga Acrenac i sur. (2012.) razlikuju tri razine prikupljanja podataka o životinjskim vrstama:

- ✓ Istraživanje divljih životinja – predstavlja utvrđivanje nazočnosti (poželjno je pri tome procijeniti brojnost i status) divlje životinje na određenom području tijekom određenog vremenskog razdoblja;
- ✓ Praćenje divljih životinja – predstavlja ponavljanje istraživanja divljih životinja tijekom vremena na određenom području kako bi se utvrdile vremenske promjene u brojnosti ili gustoći populacije te
- ✓ Gospodarenje ili upravljanje divljim životinjama – predstavlja pokušaj balansiranja između zahtjeva životinjske vrste i potreba ljudi.

Za te je potrebe razvijen cijeli niz metoda te postoji i opsežna literatura (npr. Sutherland, 2006.; O'Connell i sur., 2011.). Generalno, metode su prilagođene okruženju, skupini životinja, ciljevima istraživanja te ostalim zahtjevima projekata (npr. dostupnosti financijskih sredstava), a mogu se podijeliti na:

- ✓ invazivne – imaju izravan učinak na životinju (hvatanje živih životinja, usmrćivanje životinja itd.) i
- ✓ neinvazivne – ne zahtjevaju hvatanje i manipulaciju sa životinjama (metode transekta, metode praćenja različitih tragova, praćenje kamerama itd).


U konačnici, razvoj suvremenih tehnologija pomogao je u rješavanju pojedinih izazova i omogućio preciznije i pouzdanije strategije od onih koje su se koristile u prošlosti, osobito kod onih životinjskih vrsta koje je zbog njihove plahosti i kriptičnosti teško pratiti (vrste koje obitavaju u tropskim kišnim šumama). Stoga metode poput praćenja pomoću kamera, DNA analize te detekcija izmeta pomoću pasa, kao i razvoj metodologije interpretacije i analize podataka (satelitske snimke, ekološko modeliranje itd.) uvelike olakšavaju ovakva istraživanja.

Osim niza pogodnosti koje kamere za praćenje divljači pružaju prilikom inventarizacije divljači, one nemaju neke tipične nedostatke koji su zabilježeni kod uobičajenih tehnika inventarizacije, kao što su:

- ✓ prebrojavanje pomoću helikoptera – skupo je i u pojedinim područjima teško provedivo (Koerth i sur., 1997.);
- ✓ brojanje izmeta – predstavlja indirektnu metodu iz koje nije moguće dokučiti strukturu populacije (Mooty i Karns, 1984.);
- ✓ prebrojavanje pomoću reflektora – vjerojatnost uočavanja je dosta niska i vrlo varijabilna (Collier i sur., 2007.);
- ✓ detektiranje životinja termalnim kamerama – metoda je dosta pouzdana, ali zahtjeva skupu opremu (Collier i sur., 2007.).

Uzevši u obzir problematiku upravljanja Parkom prirode „Medvednica“, odnosno ograničenje u smislu intenzivnijeg lova pojedinih vrsta divljači te samim time i ograničenja prilikom provođenja inventarizacije vrsta, u ovom diplomskom radu se pokušalo istražiti dali je na pojedinim lokalitetima samo jednom kamerom koja će biti aktivna dulje vrijeme moguće dobiti određene podatke:

- ✓ godišnju fluktuaciju u brojnosti divljači,
- ✓ aktivnosti divljači,
- ✓ spektar životinjskih vrsta na određenom lokalitetu te
- ✓ pojedine stanišne čimbenike koji na gornje parametre imaju signifikantan utjecaj.



Slika 1. Položaj hvataljke (mjesto postavljene kamere) u Parku prirode „Medvednica“ s revirima zaštite divljači koji teritorijalno spadaju u Grad Zagreb

3. MATERIJAL I METODE

3.1. PODRUČJE ISTRAŽIVANJA



Slika 2. Izgled hvataljke u kojoj je bila smještena kamera

Istraživanje je provedeno u jugoistočnom dijelu Parka prirode „Medvednica“, koje teritorijalno spada u Grad Zagreb, na lokalitetu „Rov“ (Slika 1.). Smještena je na 370 m nadmorske visine s koordinatama 45 56' 58,643" SGŠ i 16 5' 6,067" IGD.

U tome je dijelu izgrađena hvataljka namjenjena hvatanju i obilježavanju divlje svinje (*Sus scrofa*).

Rađena je u nekoliko etapa:


- ✓ 20. studenoga 2012. zakopani su stupovi hvataljke;
- ✓ 10. siječnja 2013. je podignuta predhvataljka i koridor, a
- ✓ 19. 12. 2013. su napravljena potezna vrata tako da je hvataljka završena i stavljena u funkciju (Slika 2.).

Sama hvataljka je smještena u svojevrsnoj kotlini, u podnožju padine okrenuta prema jugozapadu (Slika 3.). Sa sjevera i zapada je okružena privatnim šumama raznodobne strukture, s istočne strane šikarom, a s južne travnjakom. Nedaleko od hvataljke na suprotnoj padini nalazi se oranična remiza, na kojoj članovi LU „Prepelica“ Sesvete siju kukuruz, zob ili djetelinsko-travnu smjesu. Iznad spomenute remize nalazi se lovačka osmatračnica. Neposredno ispod hvataljke prolazi poljski put, koji nastavlja ići kroz privatnu šumu. Kamera je od najbliže kuće (vikendice) udaljena 360 m, a od je najbližeg naselja (Planina Gornja) udaljena 1 km. I vikendice i naselja se nalaze jugoistočno od lokacije hvataljke (kamere).

Budući da na istraživanom području nije ustanovljeno lovište, dozvola za izgradnju hvataljke i postavljanje kamere je dobivena na temelju posebne dozvole (Ministarstvo poljoprivrede – sadašnji naziv i Ministarstvo zaštite okoliša i energetike–sadašnji naziv) od lovne godine 2012./2013. do lovne godine 2016./2017. Dozvole su izdane u vidu Rješenja

koja se nalaze u pismohrani Šumarskog i Veterinarskog fakulteta (provoditelji projekata „Primijenjena istraživanja divljači na području Parka prirode 'Medvednica' – Grad Zagreb“, kojeg provodi Šumarski fakultet Sveučilišta u Zagrebu te „Zdravlje divljači i zoonotski potencijal na području Parka prirode 'Medvednica' – Grad Zagreb“).

Izbor lokacije su sugerirali članovi LU „Prepelica“ Sesvete jer su primijetili da se divlja svinja tamo koncentrira.



Slika 3. Položaj i okruženje hvataljke u prostoru te konfiguracija terena (izrađena u programu ArcScene 9.3)

3.2. ZNAČAJKE KORIŠTENE KAMERE

Za razliku od telemetrijskih istraživanja praćenje divljih životinja kamerama manje uznemirava životinju. Stoga istraživanja aktivnosti divljih životinja pomoću daljinski upravljanih ili automatskih kamera imaju relativno dugu povijest (Delaney i sur., 1998.). Pri tome se koriste različite tehnike snimanja kao što su tijekom vremena (time-lapse¹), 8 milimetarske kamere, konvencionalne video kamere, minijaturne video kamere, 110 instamatične kamere te 35 milimetarske infracrvene kamere.



Slika 4. Počelo rada aktivne infracrvene kamere. Izvor: <http://www.elfiportablesecurity.com>

¹Time-lapse je posebna tehnika fotografiranja pri kojoj više fotografija nekog kadra snimamo u određenom vremenskom intervalu. Spajanjem zabilježenih fotografija u kontinuirani prikaz (barem 24 fotografije u jednoj sekundi, iako se često koristi i 30) dobiva se iluzija pokreta, odnosno dojam filma. Dobiveni video uradak je konačni produkt time-lapse fotografije. Gledanjem time-lapse video uratka, dobiva se dojam da se scena kreće ubrzano, pa se može reći da je time-lapse obrnuta tehnika od slow-motiona (Magdić i sur., 2014.).

Daljinske kamere rade na način da osjete objekte koji se ili gibaju ili imaju drugačiju temperaturu u odnosu na pozadinu. Stoga su dosta pouzdane u otkrivanju sisavaca, dok im je kod ptica primjena nešto manje pouzdana, a najmanje pouzdane su u otkrivanju gmazova i vodozemaca (Gillespie i sur., 2015.).

Recentne kamere za praćenje divljači (katkada se koristi termin i daljinske kamere – „remote cameras“) se aktiviraju infracrvenim senzorima (IC senzori), koji mogu biti aktivni (AIR) ili pasivni (PIR).

Aktivne IC kamere (AIR=Active Infrared) se aktiviraju ako objekt prekine uzak snop IC zraka koji se proteže između odašiljača i prijemnika zraka. Stoga oba uređaja moraju biti dobro postavljeni. Oni su odvojene od kamere, a IC prijemnik je kamerom povezan kablovima wireless-om (*Slika 4.*).

Pasivne IC kamere (PIR=Passive Infrared) su koncipirane na drugačiji način. One imaju jednu senzorsku sastavnicu, koja je u većini kamera integrirana u kućištu kamere. Unutar zone otkrivanja nalaze se senzori koji prepoznaju objekt koji se giba ili mu je temperatura različita od temperature okoline. Za razliku od AIR kamera, PIR kamere su puno jednostavnije za korištenje, no imaju 2 nedostatka:

- ✓ Zbog visoke osjetljivosti aktiviraju se ne samo prilikom prolaza organizma nego i pri gibanju vegetacije, prolasku sjene ili zagrijavanju tla, osobito ako su postavljene nisko.
- ✓ U toplijim klimatskim područjima zbog tople okoline senzori teško uočavaju razlike između temperature organizma i temperature okoliša.

Bez obzira na ove nedostatke u istraživanju divljih životinja uglavnom se koriste PIR kamere. Od kraja 20. stoljeća na ovamo razvoj oba sustava je bio vrlo brz tako da na tržištu danas ima velik broj proizvođača i modela PIR kamera te prilikom izbora modela treba biti dosta oprezan. Prema Trollet i sur. (2014.) temeljne značajke spomenutih uređaja su sljedeće:


1. Brzina reagiranja (aktivacije) kamere – predstavlja vrijeme zadržke potrebno kameri da snimi snimku od trenutka kada je životinja presjekla IC snop unutar zone detekcije kamere. Ovisno o proizvođaču i modelu brzina aktiviranja varira od 0,197 do 4,206 sekundi te je to jedna od ključnih značajki kamere. Kod sporih kamera (sporo okidanje) može se dogoditi da one vrste koje su dosta brze prođu ispred kamere tako da ih ona

detektira, ali zbog sporog reagiranja kamera jedinku(e) ne uspije snimiti jer je izašla iz vidnog polja kamere prije registriranja.

2. Zona detekcije kamere – ova zona varira u širini i dubini, a dosta ovisi i o modelu. Prema Rowcliffe i sur. (2011.) ova značajka određuje stopu detekcije. To je područje koje pokriva IC snop i u kome se može detektirati pokret.
3. Vidno polje kamere – predstavlja područje koje pokriva leća kamere, odnosno ono koje se javlja na snimci. Obično iznosi 42° , ali može biti i veće.
4. Vrijeme povrata kamere – je vremensko razdoblje koje prođe od okidanja (uzimanja snimke) do trenutka kada je kamera spremna uzeti idući snimak. Ovisno o modelu kamere vrijeme povrata se dosta razlikuje, no pojedini modeli mogu uzimati snimke svakih 0,5 sekundi. Kamere koje u relativno kratkom vremenskom intervalu mogu uzeti dosta snimaka je preporučljivo koristiti prilikom istraživanja prehrane pojedinih životinjskih vrsta jer daju potpunu sekvencu. U slučajevima kada je bit istraživanja usmjerena na određivanje spektra vrsta tada je bolje da je vrijeme povrata dulje jer će snimke biti jasnije.
5. Mogućnost noćnog snimanja – za noćno snimanje se mogu koristiti bljeskalice ili IC svijetlo. Bljeskalica omogućava bolju rezoluciju i, općenito, kvalitetu snimke, a snimke su u boji. Nedostatak je što bljeskalica može uplašiti ili čak razljutiti životinju (npr. smeđeg medvjeda – *Ursus arctos* i to do te mjere da on može uništiti kameru; Krapinec, usmeno). IC svijetlo može biti normalno ili tzv. „no glow“ – crna bljeskalica. Ovakvim načinom noćnog snimanja (pomoću IC svijetla) dobiju se crno-bijele snimke.
6. Rezolucija snimke – ovo i nije ključna sastavnica kvalitete snimke jer kvaliteta ovisi i o senzoru u kome se nalaze pikseli. Naime, za istu veličinu senzora s porastom broja piksela pada njihova veličina, a što su pikseli manji to su manje osjetljivi na svijetlo te proizvode više smetnji (neželjeni signali) pri čemu im je dinamički opseg uži (zapravo je uži opseg intenziteta svijetla koji se može uloviti, Nakamura, 2005.). Stoga je moguće da kamera s manje piksela i većeg broja senzora daje snimke bolje rezolucije od kamera s više piksela, a manjeg senzora. Nažalost, proizvođači veličinu senzora ne daju u specifikaciji proizvoda.

Treba istaknuti kako, ovisno o modelu kamere odnos područja otkrivanja i vidnog polja kamere može biti različit (*Slika 5.*). Naime, kod pojedinih modela je područja otkrivanja šire od vidnog polja. Ovakav odnos je bolji ukoliko se kamerom želi snimiti brze životinje. U drugome slučaju je zona otkrivanja uža od vidnog polja. Ovakav odnos je bolji ako se prate

krupni sisavci. No, treba imati na umu da životinja može biti u vidnom polju, ali izvan polja detekcije pa se okidač na kameri neće aktivirati.



Slika 5. Odnos područja otkrivanja i vidnog polja kamere. a-područje otkrivanja je šire od vidnog polja, b-područje otkrivanja je uže od vidnog polja. Izvor: Trolliet i sur., 2014.; 449 str.

Za potrebe izrade ovog diplomskog rada korištena je kamera marke Dörr, model SnapShot MOBIL Black 5.0 MP (Slika 6.). Radi se o PIR kameri rezolucije 3 ili 5 megapiksela (mogućnost izbora prilikom namještanja postavki uređaja), dimenzija 20,6 x 14,7 x 8,9 cm, što je čini relativno malenom i slabo uočljivom (glede krađe, ali i glede uočavanja od divljih životinja). Kamera ima mogućnost snimanja fotografija ili video klipova u trajanju od 5 do 60 sekundi te posjeduje relativno brz okidač koji može po jednom pomaku objekta snimiti do 3 fotografije.



Slika 6. Izgled kamere Dörr SnapShot MOBIL Black 5.0 MP. a-vanjski izgled, b-unutarnji izgled s prostorom za baterije (desna strana kamere) te ekranom i dijelom za namještanje postavki (lijeva strana kamere)

Senzori imaju mogućnost namještanja osjetljivosti na tri razine (niska, uobičajena i visoka) te interval odgode aktivacije PIR senzora od 0 do 60 minuta. Fotografije i video snimci se pohranjuju na SD karticu. Ono što je novina u značajkama ove kamere je mogućnost korištenja SIM kartice te se netom snimljena fotografija odmah šalje na željenu MMS ili e-mail adresu, a istovremeno se i pohranjuje na SD karticu. Mogućnost poslanih fotografija dnevno kreće se od 0 do 99 (ovisno o izboru). Treba naglasiti kako s obzirom na odnos zona detekcije-vidno polje, kamera spada u drugu kategoriju (*Slika 5.b*), odnosno vidno polje je šire od zone detekcije.

Na svakoj snimci je kamera bilježila vrijeme nastanka snimke (vrijeme se mora namjestiti prije postavljanja kamere), temperaturu zraka u trenutku snimanja i mjesečevu mijenu (*Slika 7.*).



Slika 7. Snimka jazavca s datumom, temperaturom i mjesečevom mijenom u trenutku snimanja

Kamera je postavljena u hvataljku na visinu od 1 m, s odgodom aktivacije senzora od 60 minuta. Razlog ovakve dugačke odgode reakcije kamere je dosta uočenih tragova divljači. Naime, htjelo se izbjeći prebrzo punjenje SD kartice, odnosno smanjiti učestalost obilaska kamere. Razina osjetljivosti PIR senzora je stavljena na normalnu, rezolucija snimaka na 3

megapiksela, a stavljena je i SIM kartica tako da je snimljena fotografija do 1 minute nakon snimanja već došla na e-mail adresu.

U hvataljku je unošen kukuruz u zrnju, jednom mjesečno od jedne do dvije vreće od 50 kg. Vrata hvataljke nisu zatvarana nego su bila otvorena tako da je divljač mogla prolaziti kroz predhvataljku i koridor. Jednom godišnje tijekom ljeta je okoliš oko hvataljke pokošen trimmerom.

Vrijeme snimanja kamere obaljeno je u dva turnusa:

- ✓ prvi turnus (trajanje snimanja) je bio od 22. travnja 2015. (kamera je postavljena u 18:30 sati) do 13. veljače 2016. (kamera je prestala s radom u 4:12 sati, zbog kvara. Stoga je prvi turnus trajao 7113:41 sati (296 dana i 6 sati).
- ✓ drugi turnus – nakon popravka kamera je postavljena 21. lipnja 2016 (u 20:00 sati), a bila je aktivna do 8 travnja 2017. (u 5:41 sati) kada je prestala slati snimke zbog kvara na SIM kartici. Drugi turnus snimanja je trajao 6985:41 sati (292 dana).

3.3. OBRADA PODATAKA I STATISTIČKE ANALIZE


Ovisno o razdoblju postavljanja i prestanka rada kamere (od 22. travnja 2015. do 8. travnja 2017.) vrijeme aktivnosti kamere je trajala različito. Osim toga, tijekom razdoblja 14. veljače 2016. – 20. lipnja 2016. kamera nije bila u funkciji tako da pojedini mjeseci nisu bili ravnomjerno zastupljeni u uzorku. Kako bi se mogao izračunati relativni indeks brojnosti, trajanje aktivnosti kamere je bilo potrebno svesti na određenu referentnu vrijednost svakog mjeseca praćenja. Stoga su za svaki dan izračunati sati aktivnosti kamere. U slučaju da je kamera radila cijeli dan ona je bila aktivna 24 sata, a u slučaju da mjesec ima 31 dan tada je ukupna aktivnost kamere trajala 744 sata, mjeseci s 30 dana aktivnost kamere je bila 720 sati. One mjesece u kojima je kamera postavljena ovo je vrijeme aktivnosti bilo znatno niže. Stoga je za svaki mjesec RAI računan na temelju individualnih sati aktivnosti kamere.

Snimke su obrađivale, odnosno determinaciju snimljenih životinja vršile dvije osobe i to istovremeno svaku snimku te nakon obrade snimke u bazu unosili slijedeće podatke: vrstu, broj i spol snimljenih životinja; vrijeme snimanja; temperaturu snimanja i mjesečevu mijenu.

S obzirom na vrijeme nastanka snimke 24-satni dan je s obzirom na vrijeme svitanja i sutona (*Slika 8.*) podijeljen na slijedeće dijelove (Rockhill i sur., 2013.):

- ✓ dan – razdoblje koje počinje 1 sat nakon izlaska sunca, a završava 1 sat prije zalaska sunca;
- ✓ noć – vremensko razdoblje koji počinje 1 sat nakon zalaska sunca, a završava 1 sat prije izlaska sunca;
- ✓ sumrak – vremensko razdoblje koje dnevno traje ukupno četiri sata. Jutarnji sumrak počinje 1 sat prije izlaska sunca, a završava 1 sat nakon izlaska sunca. Večernji sumrak počinje 1 sat prije zalaska sunca, a završava 1 sat nakon zalaska sunca.

Vrijeme izlaska i zalaska sunca je za gore navedene koordinate i nadmorsku visinu kamere izračunato pomoću algoritma danog na web stranicama Zvezdarnice Zagreb (http://astrogeo.geoinfo.geof.hr/online_efemeride/sunrise_sunset/), za svaki dan istraživanog razdoblja. Tijekom razdoblja snimanja kamera je namještana na računanje stvarnog vremena, koje se u ovoj vremenskoj zoni dijeli na ljetno i zimsko. Temeljno vrijeme je zimsko, a ljetno vrijeme su u Republici Hrvatskoj (kao i u većem broju europskih zemalja) računa od zadnje nedjelje u ožujku do zadnje nedjelje u listopadu. Ono se računa na način da se zimskom vremenu dodaje jedan sat.




Slika 8. Godišnji hod trajanja dana i noći prema izlascima i zalascima sunca od 1. siječnja 2015. do 31. prosinca 2017. za lokalitet Rov. Grafikon je izrađen prema podacima Zvezdarnice Zagreb

(http://astrogeo.geoinfo.geof.hr/online_efemeride/sunrise_sunset/)

Budući da divlje životinje ne razlikuju ljetno i zimsko vrijeme te da bi prilikom obrade podataka došlo do poteškoća prilikom prelaska na zimsko i na ljetno vrijeme vrijeme nastanka svake snimke iskazano u zimskom računanju vremena bez obzira što je snimka nastala u ljetnom računanju vremena, a na *Slici 8.* je dan grafički prikaz trajanja dana i noći s oznakom kada bi trebalo dodati jedan sat (ukoliko se želi znati kada je divljač izlazila prema ljetnom računanju vremena).

Korišteni model kamere mjesečeve mijene bilježi u oznakama od 1 do 30. Stoga ih je trebalo preračunati sukladno jednom od međunarodnih standarda. Naime, postoje dva načina razvrstavanja mjesečevih mijena. Prvi način (Roša i sur., 2016.) lunarni ciklus razvrstavaju u 4 mijene (mlađak, prva četvrt, uštap i posljednja četvrt). Međutim, američki Pomorski oceanografski portal (http://aa.usno.navy.mil/faq/docs/moon_phases.php, Naval Oceanographic Portal) navodi 8 mjesečevih mijena (*Slika 9.*). Kako je većina stranih znanstvenika u radovima koristila podjelu u skladu s tim portalom, dobiveni podaci sa snimaka kamere su svrstani u jednu od navedenih 8 kategorija (*Tablica 1.*).



Slika 9. Mjesečeve mijene prema Pomorskom oceanografskom portalu.

Prerađeno iz: https://en.wikipedia.org/wiki/Lunar_phase

Tablica 1. Način preračunavanja mjesečevih mijena iz kamere u mjesečeve mijene prema američkom Pomorskom Oceanskom Portalu

MIJENA PREMA KAMERI	NAZIV MIJENE	OZNAKA MIJENE	MIJENA PREMA KAMERI	NAZIV MIJENE	OZNAKA MIJENE
1	mlađak	1	16	uštap	5
2	mlađak	1	17	padajuće ispunčen	6
3	mlađak	1	18	padajuće ispunčen	6
4	rastuće srpolik	2	19	padajuće ispunčen	6
5	rastuće srpolik	2	20	padajuće ispunčen	6
6	rastuće srpolik	2	21	zadnja četvrt	7
7	prva četvrt	3	22	zadnja četvrt	7
8	prva četvrt	3	23	zadnja četvrt	7
9	prva četvrt	3	24	padajuće srpolik	8
10	rastuće ispunčen	4	25	padajuće srpolik	8
11	rastuće ispunčen	4	26	padajuće srpolik	8
12	rastuće ispunčen	4	27	padajuće srpolik	8
13	rastuće ispunčen	4	28	mlađak	1
14	uštap	5	29	mlađak	1
15	uštap	5	30	mlađak	1

Na temelju dobivenih podataka izrađeni su grafikoni aktivnosti životinja s obzirom na mjesec, mjesečeve mijene i temperaturu zraka, dok je za procjenu brojnosti divljači korišten relativan indeks brojnosti (RAI), koji se računa prema slijedećem obrascu:

$$RAI = \frac{\text{broj snimljenih jedinki}}{\frac{\text{broj dana snimanja}}{100}}$$

Indeks predstavlja broj uočenih jedinki s obzirom na 100 dana snimanja. U ovome diplomskome radu je indeks računan za svaki mjesec te na godišnjoj razini, za svaku vrstu divljači, koja je uočena na kameri. Za izračun RAI-a korišteno je kumulativna duljina aktivnosti kamere za svaki mjesec bez obzira koje je godine kamera bila aktivna.

Kod srneće divljači je na snimkama određivan spol prema metodi Hespeler i Krewer (2003.), Međutim, u pojedinim slučajevima nije bilo moguće odrediti spol jer na snimci nisu bili ni glava ni ogledalo jedinke.

Podaci su analizirani u programskom paketu StatSoft 12. (Dell Inc., 2015.). Izjednačenje ovisnosti temperature zraka tijekom aktivnosti životinje i mjeseci u godini načinjena je kvadratnom funkcijom.

4. REZULTATI

4.1. GODIŠNJA DINAMIKA BROJA SNIMAKA TE RELATIVNI INDEKSI BROJNOSTI

Tijekom istraživanog razdoblja kamera je bila aktivna 14 038,37 sati (preračunato u heksagezimalnu jedinicu to iznosi 14 038 sati i 42 minute), što čini 586,81 dan (preračunato u heksagezimalne jedinice to iznosi 586 dana, 19 sati i 26 minuta). Pri tome je kamera snimila 1 799 snimaka, od čega 462 prazne snimke (snimke na kojima nije bilo snimljenih životinja), te 1 337 iskoristivih snimaka (snimke na kojima je bilo jedna ili više životinja).

Ovo čini udio praznih snimaka od 26 %. Međutim, iz *Tablice 2.* se može vidjeti kako je kumulativno mjesečno vrijeme aktivnosti kamere dosta različito. Kamera je najdulje bila aktivna tijekom siječnja, srpnja, kolovoza, listopada i prosinca (62 dana), dok je gotovo upola manje bila aktivna u ožujku i svibnju (31 dan), a najmanje je bila aktivna u travnju (15,47 dana, odnosno 15 dana, 11 sati i 17 minuta).

Tablica 2. Kretanje napora uzorkovanja te odnos iskoristivih i praznih snimaka tijekom razdoblja praćenja divljači na lokalitetu Rov

MJESECI	NAPOR UZORKOVANJA (sati ²)	NAPOR UZORKOVANJA (dani)	ukupni broj snimak a	broj prazn ih snima ka	iskoristive snimke	udio prazn ih snima ka (%)	udio iskorišteni h snimaka (%)
Siječanj	1 488,00	62,00	261	103	158	39	61
Veljača	964,20	40,18	160	65	95	41	59
Ožujak	744,00	31,00	209	48	161	23	77
Travanj	371,17	15,47	61	28	33	46	54
Svibanj	744,00	31,00	57	31	26	54	46
Lipanj	940,00	39,17	49	8	41	16	84
Srpanj	1 488,00	62,00	87	33	54	38	62
Kolovoz	1 488,00	62,00	134	33	101	25	75
Rujan	1 440,00	60,00	159	27	132	17	83
Listopad	1 488,00	62,00	81	12	69	15	85
Studeni	1 440,00	60,00	299	31	268	10	90
prosinac	1 488,00	62,00	242	43	199	18	82
UKUPNO	14 083,37	586,81	1 799	462	1 337	26	74


² dani i sati su izraženi u decimalnim jedinicama

Vrijeme prve detekcije životinja (vrijeme proteklo od postavljanja kamere pa do trenutka kada je prva životinja detektirana) u prvome turnusu (kamera je postavljena 22. travnja 2015.) je iznosilo:

- ✓ jazavac – 5 dana (detektiran je 26. travnja 2015.),
- ✓ divlja svinja - 11 dana (detektirana je 2. svibnja 2015.),
- ✓ srna obična – 15 dana (detektirana je 6. svibnja 2015.),
- ✓ lisica – 77 dana (detektirana je 7. srpnja 2015.).

U drugome turnusu snimanja (kamera je postavljena 21. lipnja 2016.) vrijeme prve detekcije je iznosilo:

- ✓ jazavac – 169 dana (detektiran je 6. prosinca 2016.),
- ✓ divlja svinja - 28 dana (detektirana je 18. srpnja 2016.),
- ✓ srna obična – 4 dana (detektirana je 24. lipnja 2016.),
- ✓ lisica – 27 dana (detektirana je 17. srpnja 2016.).



Slika 10. Broj snimaka prema vrsti životinje

Najučestalije je detektirana srneća divljač (1 106 snimaka), divlju svinju-*Sus scrofa* (67 snimaka), lisicu-*Vulpes vulpes* (48 snimaka) i jazavca-*Meles meles* (23 snimke). Od ptica su zabilježene: šojka kriještlica (*Garrulus glandarius*, 6 snimaka), velika sjenica (*Parus major*, 4 snimke), obična zeba (*Fringilla coelebs*, 2 snimke), brgljez (*Sitta europae*, 1 snimka)

i sivi ćuk (*Athene noctua*, 1 snimka), dok na 4 snimke nije bilo moguće odrediti vrstu. Kod kuna je na dvije snimke bilo jasno uočljivo da se radi o bjelici, dok na dvije snimke ne, no jasno je da se radi o kunama. Kamera ih je detektirala u ožujku, lipnju, srpnju i studenome. Fazan (*Phasianus colchicus*) je detektiran u ožujku i travnju (vrijeme izbora teritorija i parenje), europski zec (*Lepus europaeus*) i divlja mačka (*Felis silvestris*) u ožujku, a čagalj (*Canis aureus*) u siječnju (Slika 10.). Budući da su na snimkama učestalije otkrivene srna obična, divlja svinja, lisica i jazavac oni će se obrađivati u daljnjoj analizi.

Ukoliko se iz dobivenog broja slika izračuna RAI, tada se iz *Tablice 3* može vidjeti kako je relativno najveći broj snimaka snimljen u ožujku, pri čemu je istog mjeseca snimljeno relativno puno praznih snimaka (RAI=155), dok je najmanje praznih snimaka snimljeno u listopadu (RAI=19), a listopad je jedan od 5 mjeseci s najduljom aktivnošću kamera.

Vrijednosti RAI-a pokazuju relativno veliku godišnju dinamiku. Srneća divljač je na području Rova bila nazočna cijelu godinu. Kod ženki srneće divljači broj snimljenih jedinki je kulminirala od studenog do ožujka, a tijekom razdoblja svibanj – srpanj ona iznosi najmanje (RAI se kreće od 3 do 43). RAI srnjaka pokazuje dva vrhunca – ožujak (RAI=161) i studeni (RAI=103). Ova kulminacija brojnosti se poklapa s kulminacijom brojnosti srna, ali i jedinkama nepoznatog spola. Razlog kulminacije brojnosti srneće divljači na hranilištu bi mogao biti zahlađenje, no vrhunac posjećenosti hranilišta u ožujku je dosta teško objasniti.

Tablica 3. Relativni indeksi brojnosti broja snimaka te vrsta divljači


MJESECI	ukupan broj snimaka	broj praznih snimaka	broj iskoristivih snimaka	srna obična				divlja svinja	lisica	jazavac
				M	F	M+F	?			
Siječanj	421	166	255	74	110	5	40	6	8	0
Veljača	398	162	236	87	95	2	45	0	7	0
Ožujak	674	155	519	161	145	6	100	16	48	3
Travanj	394	181	213	45	65	0	13	13	13	45
Svibanj	184	100	84	26	3	3	3	10	0	39
Lipanj	125	20	105	15	43	0	20	15	0	0
Srpanj	140	53	87	11	15	2	15	31	5	0
Kolovoz	216	53	163	15	81	0	29	34	5	0
Rujan	265	45	220	42	80	0	95	2	2	0
Listopad	131	19	111	18	58	0	34	0	0	2
Studen	498	52	447	103	190	22	110	8	10	2
prosinac	390	69	321	61	150	6	84	2	16	2
UKUPNO	307	79	228	52	90	4	52	11	8	4

Divlja svinja nije zabilježena na kameri u veljači i listopadu. Vrhunac brojnosti divlje svinje u predjelu praćenja je bio tijekom ljetnih mjeseci (srpanj-RAI=31 i kolovoz-RAI=34), no u odnosu na srneću divljač indeks njene brojnosti je znatno niži. Međutim, osim u srpnju i kolovozu crna se divljač na hranilištu pojavljivala od ožujka do lipnja (RAI se kretao od 10 do 16).


Lisica nije detektirana u svibnju, lipnju i listopadu. Najučestalije je bila detektirana u ožujku (RAI=48), a onda slijedi izvjesna latenca do studenog i prosinca. Jazavac je detektiran još rjeđe. U siječnju i veljači nije detektiran (vjerojatno zato jer je bio na brloženju), a isto tako nije detektiran od lipnja do rujna. Njegova aktivnost je najviša u travnju i svibnju.

4.2. DNEVNA AKTIVNOST DIVLJAČI TIJEKOM ISTRAŽIVANOG RAZDOBLJA

Općenito gledano, godišnja aktivnost srneće divljači pokazuje dva maksimuma (*Slika 11.*). Prvi je maksimum u ožujku, a drugi u studenome, dok je od svibnja do srpnja ta aktivnost najmanja. Doduše, postoji još jedan pad aktivnosti u listopadu, ali je teško proniknuti zbog čega. Iz *Slike 11.* jasno je kako je srneća divljač veći dio godine najaktivnija noću, a nakon toga tijekom sumraka, dok aktivnost tijekom svijetlog dijela dana ne pokazuje značajne oscilacije i vrlo je mala. Treba istaknuti kako je tijekom spomenutog razdoblja minimalne aktivnosti srne obične (svibanj-srpanj) aktivnost viša tijekom sumraka nego tijekom noći. Mogući razlog spomenutog pada aktivnosti mogla bi biti i sezona lova na srnjaka koja počinje 1. svibnja, a završava 30. rujna. Drugi minimum aktivnosti se može povezati s početkom lova na srne i lanad, koji počinje 1. listopada.



Slika 11. Mjesečna dinamika aktivnosti srneće divljači tijekom istraživanog razdoblja




Slika 12. Mjesečna dinamika aktivnosti divlje svinje tijekom istraživanog razdoblja


Za razliku od srneće divljači, crna divljač pokazuje sasvim suprotan hod dnevne aktivnosti. Naime, ona kulminira od ožujka do kolovoza (*Slika 12.*), iako se, poznavajući veliki životni prostor divlje svinje, ne može donijeti generalan zaključak jer je ona u ovome istraživanju promatrana na samo jednoj lokaciji. No, generalno se može uočiti kako je divlja svinja, za razliku od srne obične uglavnom noćna životinja. Tijekom dana se kreće dosta rijetko (ovdje je zabilježena aktivnost od svibnja do srpnja), a u sumrak svega nekoliko mjeseci (siječanj, travanj, srpanj-maksimum i kolovoz). Treba istaknuti kako su na snimkama uglavnom zabilježene krmače s prasadi, a vrlo malo samotnjaka. Stoga bi se vrhunac aktivnosti tijekom spomenutog razdoblja mogao povezati s pojačanim trofičkim potrebama (laktacija, podizanje prasadi), a tijekom zime je vjerojatno svinja posjećivala druga, otvorena

hranilišta na Medvednici (ili oko nje) koja su joj se činila sigurnijima. Naime, ovo hranilište je bilo ograđeno i svinje su se uglavnom držale izvan hvataljke (za razliku od srneće divljači). S druge strane, smanjena nazočnost crne divljači u rujnu i izostanak njene detekcije (recimo pojave) na lokalitetu u listopadu moglo bi se povezati s dozrijevanjem teškog šumskog sjemena (kesten, žir, bukvice). Naime, na lokalitetu se nalaze privatne šume relativno loše kvalitete, no prema zapadu (prema središtu Medvednice raste udio šumskih sastojina bukve, hrasta kitnjaka i pitomog kestena, koje su uglavnom u državnom vlasništvu i dobro su izgospodarene (Krapinec, 2010.). Stoga je divlja svinja tijekom tih mjeseci intenzivnije boravila u područjima obraslim sastojinama obične bukve, hrasta kitnjaka i pitomog kestena.

Iako su lisica i jazavac na istraživanom lokalitetu bili detektirani povremeno, svejedno se može donijeti određena predodžba njihove aktivnosti. Lisica pokazuje maksimum aktivnosti od studenog (kasna jesen) do travnja, a povremena aktivnost je zabilježena od srpnja do rujna (*Slika 13.*). Razlog ovakve aktivnosti je disperzija mladunčadi, koja nastupa od početka jeseni, a odmah nakon toga i razdoblje parenja koje već može početi u siječnju. Zbog relativno kratke gravidnosti lisice (53 dana) štenad dolazi na svijet već krajem ožujka ili početkom travnja te su roditelji izrazito aktivni kako bi se zadovoljile trofičke potrebe laktirajućih ženki, ali i mladunčadi koja već nakon nekoliko tjedana prestaje sa sisanjem. Zbog velikog životnog prostora lisice vjerojatno je tijekom svibnja i lipnja hranu tražila u drugom dijelu svog životnog prostora, iako treba istaknuti da se 80 metara sjeverno od hvataljke nalazi jazbina s 4 ulaza (Konjević i Krapinec, 2014.), koju koriste lisica i jazavac.



Slika 13. Mjesečna dinamika aktivnosti lisice tijekom istraživanog razdoblja




Slika 14. Mjesečna dinamika aktivnosti jazavca tijekom istraživanog razdoblja

Jazavac je pokazao slabiju aktivnost od lisice, no iako je bio detektiran svega 6 mjeseci tijekom godine, njegova aktivnost je gotovo isključivo vezana za noć (*Slika 14.*). Pri tome se jasno može uočiti vrhunac aktivnosti tijekom travnja i svibnja. Ova je aktivnost gotovo dvostruko viša od aktivnosti lisice tijekom travnja ($RAI=45$), a najvjerojatnije je povezana s prestankom brloženja i intenzivnom potragom za krmivima. Stoga i ne čudi da je učestalo posjećivao hranilište (hvataljku). U sumrak ga je kamera zabilježila samo jednom i to u svibnju u 4:06 sati (5:06 sati po ljetnom računanju vremena). Nakon toga je slijedila izvjesna stanka u posjećivanju hvataljke, da bi pred kraj jeseni (listopad-prosinac) bio na hvataljki zabilježen nekoliko puta, a razlog je intenzivna ishrana kukuruzom radi pripreme za zimsko brloženje. Generalno, to ne znači da lisica i jazavac tijekom spomenutih mjeseci, kada nisu detektirani na lokalitetu, nisu bili aktivni, nego im je životni prostor relativno velik, a mogli su proći i iza kamere. Stoga je teren trebalo „pokriti“ s više kamera ili kameru postaviti neposredno uz spomenutu obližnju jazbinu. Time bi se dobili relevantniji podaci o aktivnosti ova dva predatora.


4.3. UTJECAJ MJESEČEVIH MIJENA NA AKTIVNOST DIVLJAČI

Za analizu utjecaja mjesečevih mijena na aktivnost divljači korištena je samo noćna aktivnost životinja. Na godišnjoj razini razlike u dinamici aktivnosti dosta su slabo izražene (Slika 15.). Kod srneće divljači (koja je na kamerama detektirana tijekom cijele godine) najviša aktivnost je zabilježena tijekom faza padajuće ispupčenog Mjeseca, mlađaka, padajuće srpolikog Mjeseca i zadnje četvrti, a najmanje je aktivna u fazi uštapa (punog Mjeseca). Treba istaknuti kako su faze 6 (padajuće ispupčen), 7 (zadnja četvrt), 8 (padajuće srpolik) i faza 1 (mlađak) mjesečeve mijene koje nastupaju nakon punog Mjeseca (iako faza mladog Mjeseca predstavlja početak novog lunarnog ciklusa).




Slika 15. Dinamika noćne aktivnosti divljači prema mjesečevim mijenama za cijelu godinu


Divlja svinja najvišu noćnu aktivnost također pokazuje tijekom razdoblja mladog Mjeseca, a nakon toga u vrijeme uštapa pa u vrijeme rastuće ispupčenog Mjeseca, zadnje četvrti i padajuće srpolikog Mjeseca. Lisica pokazuje razmjerno najvišu noćnu aktivnost u vrijeme padajuće srpolikog Mjeseca, a najmanju u fazi rastuće srpolikog Mjeseca (faza 2), dok jazavac najnižu stopu aktivnosti pokazuje u fazi 1 (mlađak) i 2 (rastuće srpoliki Mjesec).




Slika 16. Dinamika noćne aktivnosti divljači prema mjesečevim mijenama tijekom siječnja




Slika 17. Dinamika noćne aktivnosti divljači prema mjesečevim mijenama tijekom veljače




Slika 18. Dinamika noćne aktivnosti divljači prema mjesečevim mijenama tijekom ožujka



Slika 19. Dinamika noćne aktivnosti divljači prema mjesečevim mijenama tijekom travnja




Slika 20. Dinamika noćne aktivnosti divljači prema mjesečevim mijenama tijekom svibnja




Slika 21. Dinamika noćne aktivnosti divljači prema mjesečevim mijenama tijekom lipnja

Gledano po mjesecima dinamika pokazuje daleko manju pravilnost (Slike 16. do 27.). Općenito je problem što su podaci iz travnja i svibnja najmanje zastupljeni, čak i kod srne obične. No, može se uočiti da je u ostatku godine srneća divljač najmanje aktivna u siječnju, srpnju, rujnu (najjasnija distribucija). Ta rujanska distribucija se u potpunosti podudara s


pretpostavkom da će dinamika aktivnosti biti obrnuto proporcionalna s noćnom iluminacijom (količinom osvjetljenja) Mjeseca. Naime, ona je najmanja za vrijeme mladaka (kada nema mjesečine), postepeno raste do faze uštapa i nakon toga ponovo postepeno pada do mijene mladog mjeseca. No, niti jedan mjesec nije zabilježeno da bi aktivnost srneće divljači bila najviša tijekom punog Mjeseca.




Slika 22. Dinamika noćne aktivnosti divljači prema mjesečevim mijenama tijekom srpnja




Slika 23. Dinamika noćne aktivnosti divljači prema mjesečevim mijenama tijekom kolovoza




Slika 24. Dinamika noćne aktivnosti divljači prema mjesečevim mijenama tijekom rujna



Slika 25. Dinamika noćne aktivnosti divljači prema mjesečevim mijenama tijekom listopada



Slika 26. Dinamika noćne aktivnosti divljači prema mjesečevim mijenama tijekom studenoga



Slika 27. Dinamika noćne aktivnosti divljači prema mjesečevim mijenama tijekom prosinca

Divlja svinja pokazuje daleko manju pravilnost aktivnosti. Međutim, čini se da joj uštap ne smeta jer je čak tijekom tri mjeseca (srpanj, rujan i studeni) pokazivala maksimum aktivnosti tijekom uštapa. U siječnju, ožujku i kolovozu je pokazivala najvišu noćnu aktivnost tijekom mlađaka. Treba istaknuti da je za noćni lov divlje svinje (doček) najpoželjnija kombinacija pun Mjesec i snijeg jer je tada najjači kontrast između divlje svinje i podloge (lakše uočavanje i ciljanje), no tijekom zime (prosinac, siječanj i veljača) je općenito divlja svinja slabo izlazila na hranilište.

Tijekom razdoblja intenzivne aktivnosti lisice (studen-travanj) njena aktivnost je intenzivnija tijekom faza manje iluminacije Mjeseca (faze 1, 2, 7 i 8), iako je u ožujku i studenom zabilježena njena pojava i tijekom uštapa, ali i tijekom faze rastuće (faza 4) i padajuće ispupčenog Mjeseca (6) tijekom veljače, ožujka, travnja, kolovoza (razdoblje niže aktivnosti lisice) i studenog, kada je također iluminacija nešto jača.

Tijekom noćne aktivnosti jazavac pokazuje najmanju osjetljivost na količinu svjetla. One mjesece kada je zabilježena njegova najviša aktivnost (travanj-svibanj) najaktivniji je bio tijekom povišene iluminacije (faza 3 do 7).

4.4. UTJECAJ TEMPERATURE ZRAKA NA AKTIVNOST DIVLJAČI


Rasponi minimalnih i maksimalnih temperatura zraka zabilježeni tijekom aktivnosti životinje pokazuju određen logičan godišnji slijed. Iz *Tablice 4.* može se vidjeti kako je srneća divljač aktivna i pri dosta visokim temperaturama (u kolovozu i do 32 °C, a u rujnu do 30 °C). Osim toga, za razliku od divlje svinje, u hladnijem dijelu godine srna je aktivnija pri nižim temperaturama (najniža izmjerena temperatura tijekom noćne aktivnosti srne je bila -10 °C).

Tablica 4. Minimumi i maksimumi temperature zraka tijekom aktivnosti divljači


MJESECI	SRNA OBIČNA						DIVLJA SVINJA				LISICA				JAZAVAC	
	DAN		NOĆ		SUMRAK		NOĆ		SUMRAK		NOĆ		SUMRAK		NOĆ	
	n	min-max (°C)	n	min-max (°C)	n	min-max (°C)	n	min-max (°C)	n	min-max (°C)	n	min-max (°C)	n	min-max (°C)	n	min-max (°C)
SIJEČANJ	14	-5 do 4	87	-10 do 4	41	-10 do 9	3	-6 do 2	3	-3	3	-6 do -3	2	0		
VELJAČA	4	-2 do 4	54	-5 do 7	34	-4 do 8					3	-2 do 2				
OŽUJAK	20	2 do 15	74	-2 do 11	34	-2 do 12	5	1 do 3			6	-2 do 8	6	-2 do 10	1	10
TRAVANJ	3	8 do 15	11	2 do 7	5	2 do 11	1	6	1	9	2	2 do 7			7	3 do 10
SVIBANJ	3	8 do 12	2	7 do 11	6	5 do 14	2	10 do 11							11	2 do 14
LIPANJ	4	6 do 12	12	4 do 15	15	3 do 11	5	7 do 14								
SRPANJ	6	10 do 28	7	11 do 17	13	11 do 26	12	12 do 19	6	10 do 16	2	10 do 16	1	14		
KOLOVOZ	8	12 do 32	41	4 do 17	28	5 do 22	20	5 do 16	1	20	2	16	1	13		
RUJAN	9	7 do 30	86	3 do 20	35	3 do 17	1	12			1	10				
LISTOPAD	3	4 do 12	47	2 do 11	18	0 do 14									1	2
STUDENI	11	-2 do 6	185	-5 do 11	59	-2 do 13	5	0 do 5			6	-4 do 4			1	3
PROSINAC	7	-2 do 2	147	-8 do 7	33	-8 do 4	1	2			6	-2 do 0	3	-3 do 1		

S obzirom da divljač pokazuje određenu sklonost ka aktivnosti tijekom noći i sumraka (krepuskularnost), a isto tako i o dobu godine, ovisnost temperature zraka o aktivnosti divljači je razlučena na dob dana i mjeseca u godini. Pri tome je jedino za srneću divljač bilo moguće načiniti regresijski model za sva tri doba dana (dan, noć i sumrak), dok je za ostale vrste, zbog nedovoljne količine podataka rađena uglavnom za sumrak i noć.


Dinamika kretanja temperatura zraka prilikom aktivnosti srneće divljači, neovisno o dobu dana kada je bila aktivna, pokazuje određenu povezanost s dinamikom aktivnosti (*Slika 11.* i *Slika 28.*). Naime, odnos ovih dviju dinamika je obrnuto proporcionalan. Tijekom najnižih temperatura zraka (zimski mjeseci) aktivnosti srne su bile najviše i obrnuto (tijekom ljetnih mjeseci je aktivnost najniža). Ako se pogleda *Slika 28.* može se uočiti kako je razlika u temperaturi zraka tijekom aktivnosti srne obične između dnevne, noćne i sumračne aktivnosti najniža tijekom hladnijeg dijela godine (od studenog do ožujka), a najveća tijekom toplijeg dijela godine (od travnja do listopada).



Slika 28. Ovisnost temperature zraka tijekom aktivnosti srneće divljači o mjesecima



Slika 29. Ovisnost temperature zraka tijekom aktivnosti divlje svinje o mjesecima



Slika 30. Ovisnost temperature zraka tijekom aktivnosti lisice i jazavca o mjesecima

Kod divlje svinje je ovisnost aktivnosti i temperature zraka potpuno obrnuta nego kod srne obične (*Slika 12.* i *Slika 29.*) – najviša razina aktivnosti je pri višim temperaturama zraka (travanj-rujan), a s obzirom na razliku između sumračnih i noćnih temperatura ne može se uočiti neka povezanost. Međutim, treba uočiti kako je krivulja noćne temperature pri aktivnosti divljači nešto viša kod divlje svinje u odnosu na srneću divljač.

Za razliku od divlje svinje i jazavca, lisica pokazuje sličan odnos ovisnosti temperature zraka tijekom aktivnosti i ritma kretanja. Pri nižim temperaturama je aktivnija, dok je pri višim manje aktivna (*Slika 13.* i *Slika 30.*). U hladnijem dijelu godine (siječanj, veljača i ožujak) je tijekom sumraka aktivna na višim temperaturama nego tijekom noći. U lovačkim krugovima je uvriježeno mišljenje kako, za razliku od srne obične i divlje svinje (ali i ostalih biljoždera), lisica obično lovi tijekom noći, a ujutro se često može vidjeti kako se vraća u jazbinu, bilo da nosi lovinu ili se vraća sita (iako ne mora značiti da joj je izlazak bio uspješan). Ovu bi tvrdnju svakako trebalo još provjeriti. U svibnju se krivulje temperature noćne i sumračne aktivnosti lisice više-manje poklapaju i to traje do studenog, kada se opet može uočiti razlika u temperaturi.

Kod jazavca nema neke povezanosti između temperature i aktivnosti. On kao da je „tempiran“ na određenu temperaturu aktivnosti, koja se kreće od 0 do 10 °C (*Slika 14.* i *Slika 30.*).

5. RASPRAVA

5.1. METODOLOGIJA OBRADE SNIMAKA DOBIVENIH KAMERAMA ZA PRAĆENJE DIVLJAČI

Foto klopke ne samo da se u značajkama mogu znatno razlikovati između različitih proizvođača nego čak i unutar istog modela. Hugson i sur. (2010.) su proveli testiranje kamera 4 različita proizvođača, pri čemu su unutar istog proizvođača ispitane značajke dva ista modela PIR kamera triju različitih proizvođača. Među modelima velika je razlika bila u udjelu praznih snimaka (snimka na kojima nije zabilježena niti jedna životinja), a ona se kretala od 7 % (kamera marke Wildlife Pro) do 56 % (Leaf River Digital Trail Scan). Pri tome je važno naglasiti kako su kamere Cuddeback Expert 3.0 digital bile najkonzistentnije. To znači da nije bilo velike razlike u udjelu praznih snimaka (kod oba primjerka istog modela udio praznih snimaka je iznosio 16 %). Nadalje Cuddeback kamere su snimile neke vrste koje ostali modeli nisu snimili. No jedna od Cuddeback kamera nije detektirala crnorepog jelena (*Odocoileus hemionus*), dok su ga ostale kamere otkrile (uključujući i drugu Cuddeback kameru istog modela). Autori zaključuju kako različite marke kamera pokazuju različitu osjetljivost na različite vrste životinja, ali ih i snimaju u različitim intervalima. Stoga i dinamika aktivnosti ovisi o vrsti kamere kojom su dobivene snimke na temelju kojih se ona izračunala. Generalno, modeli su se međusobno dosta razlikovali:

- ✓ po osjetljivosti,
- ✓ po širini zone detekcije (npr. kamera marke Reconyx Silent Image ima dosta široko polje detekcije što rezultira i s dosta praznih snimaka),
- ✓ po kvaliteti snimaka,
- ✓ djelovanju u različitim položajima ili orijentacijama (npr. isti model kamere pri različitim položajima daje različite rezultate snimanja),
- ✓ konzistentnosti – čak i unutar istog modela kamere postoje razlike u intenzitetu snimanja. Naime, čini se kako se svaka kamera nastoji stabilizirati na detekciju različitog broja vrsta.

Očito je da, iako se foto klopke u istraživanjima koriste već dulji niz godina, njihove značajke nisu standardizirane, no prikupljene slike i pri lošije dizajniranom uzorkovanju još uvijek mogu dati korisne podatke (Jenks i sur., 2011.). Prilikom obrade podataka, odnosno snimaka, ovisno o cilju istraživanja potrebno je izračunati neke temeljne pokazatelje. Već je rečeno kako cilj istraživanja može biti utvrđivanje: nazočnosti određene vrste u staništu, broja

vrsta, prostornog rasporeda jedinki i brojnosti. S time u svezi je i izbor parametara koji će se računati iz dobivenih snimaka.


Prema Acrenac i sur. (2012.) to se u prvome redu odnosi na izračun tzv. napora uzorkovanja. U pojedinoj literaturi se još koristi termin broj dana snimanja ili broj lovnihi noći. Jednostavno rečeno, on predstavlja broj dana kada je jedna kamera snimala, ne računajući dane kada ona nije radila. Ukoliko je u istraživanju korišteno više kamera tada broj dana predstavlja ukupan broj dana snimanja svih postavljenih kamera. U slučaju da su na jednoj lokaciji postavljene dvije kamere (capture-recapture sampling) tada se za tu lokaciju (točku) računa 1 lovni dan po danu rada obiju kamera bez obzira što su postavljene dvije. U tom slučaju su nelovni dani oni kada na poziciji nisu radile obje kamere.

Prilikom utvrđivanja nazočnosti pojedine vrste treba paziti da se ne nazočnost ne poveže s tzv. „lažnom odsutnošću“. Naime, ukoliko neku vrstu za koju se očekuje da će biti u području istraživanja kamera nije zabilježila to još uvijek nije dokaz da nje u tom području nema jer sposobnost detektiranja kamere nije idealna.

Kao pokazatelj brojnosti neke vrste može se koristiti tzv. indeks relativne brojnosti – RAI³ (Carbone i sur., 2001; O’Brien, 2003.). On predstavlja broj slika na kojima je neka vrsta zabilježena tijekom 100 lovnihi noći (24-satnog dana).

Prije nego se pristupi obradi snimaka potrebno je znati radi li se o vrsti kod koje je na temelju određenih individualnih značajki moguće razlučiti jedinke (šare, pruge, rogovlje itd.). Ukoliko to nije moguće tada je pouzdanost dobivenih podataka relativno slaba. Prednosti vrsta koje ne možemo razlučiti na razini jedinke je što se indeksi brojnosti relativno jednostavno računaju. Međutim, postoji nekoliko nedostataka u korištenju RAI-a, a jedan od njih je čak i ograničenje u detektiranju vrste. Naime, kamere mogu biti tako postavljene da njihov položaj odgovara detektiranju određenih vrsta, a drugih ne. Primjerice, ako su postavljene na staze divljači tada će snimati vrste koje se vole koristiti stazama, a one vrste koje izbjegavaju postojeće staze neće snimati. Time nastaje pristranost, odnosno brojnost prve skupine vrsta će biti precijenjena. Iz tog razloga Gillespie i sur. (2015.) razlikuju dva termina – nazočnost i otkrivenost (*Slika 31.*).

³Relative Abundance Index



Slika 31. Razlika u detekciji (lijeva slika) i nazočnosti (desna slika) životinje istraživane foto klopkom (kamerom). Izvor: Gillespie i sur., 2015., 7 str.

Kod izračuna RAI-a nazočnost se, u stvari poistovjećuje s detekcijom što u sebi skriva pogrešku. Prema Gillespie i sur. (2015.) vjerojatnost otkrivanja predstavlja vjerojatnost da će neka vrsta tijekom praćenja biti otkrivena ukoliko je na području istraživanja nazočna. Na primjer, ukoliko su mogućnosti za otkrivanje vrste u istraživanju 50 %, a osoblje provodi 3 praćenja (repeticije) na lokalitetu tada su prilike da se vrsta neće otkriti bez obzira što je tamo nazočna 12,5 % ($0,5 \times 0,5 \times 0,5 = 0,125$). Ako su dosadašnja praćenja pokazala da je vrsta stvarno nazočna na 1 od 4 lokaliteta (t.j. zauzetost je 0,25) unutar sličnog staništa, tada u slučaju da se praćenje vrši na 100 lokaliteta, možemo očekivati da će u prosjeku vrsta biti nazočna na 25 lokaliteta ($100 \times 0,25 = 25$). Ukoliko se planira vrstu dalje pratiti u 3 repeticije na svakom lokalitetu, a vjerojatnost detektiranja vrste je 50 % po repeticiji tada se vrstu može detektirati na 22 lokaliteta, prema obrascu: $1 - 0,125 \times 25 = 21,8$ lokaliteta. Pri tome postoji 4 % mogućnosti da je ta vrsta nazočna i na lokalitetu gdje nije detektirana usprkos provedene tri repeticije. Računski to izgleda ovako:

- ✓ Broj lokaliteta gdje vrsta nije detektirana, ali je nazočna: $25 - 22 = 3$,
- ✓ Broj lokaliteta na kojima se očekuje da vrsta nije nazočna: $100 - 25 = 75$,
- ✓ Vjerojatnost da je vrsta nazočna na lokalitetima gdje nije detektirana tijekom 3 repeticije: $3 / (3 + 75) = 0,038$ (4 %).


Rowcliffe i sur. (2008., 2016.) su predložili model procjene gustoće populacije onih vrsta koje je teško identificirati na razini jedinke. Pri tome su gustoća populacije funkcija učestalosti bilježenja (stopa detekcije) vrste i njene brzine. Prema njima, su korelacije između stope hvatanja (snimanja) i gustoće populacije pouzdane samo onda ako ih se rekalkulira za svaku lokaciju i vremensko razdoblje. Brzinu jedinki je također moguće izračunati iz dobivenih snimaka. No, njihov model zahtjeva slučajan izbor mjesta postavljanja kamera u odnosu na gibanje životinje, odnosno kamere se ne smiju postavljati na mjesta poznate

aktivnosti životinja kao što su prometnice. Za razliku od Rowcliffe i sur. (2008.; 2016.), Royle i Nichols (2003.) su predložili metodu kod koje se procjena brojnosti zasniva na varijabilnosti u vjerojatnosti detektiranja vrste u prostoru na svakoj točki uzorkovanja (postavljene kamere). Ovaj model samo zahtjeva podatke o tome je li vrsta na određenoj točki detektirana ili nije.

Kod onih vrsta kod kojih je moguće identificirati jedinku brojnost se može izračunati na temelju modela hvatanja i ponovnog hvatanja (Karanth i Nichols, 1998.) ili prostornog modela hvatanja i ponovnog hvatanja (Spatial Capture-recapture – SCR), a metodologiju su razvili Karanth i sur. (2006.) te Gardner i sur. (2010.).

Generalno, ukoliko se pomoću kamere želi pratiti dinamika populacije tada je postavljanje pokusa (način uzorkovanja) daleko složenije. Rezultati istraživanja koje su proveli Gomper i sur. (2006.) su pokazali da je praćenje sitnih kanida daleko pouzdanije vršiti pomoću DNK analize ili praćenjem tragova u snijegu. Budući da detekcija ovisi i o mjestu postavljanja kamere ono se ne bi smjelo birati subjektivno (nasumično) nego generiranjem slučajnih brojeva, odnosno metodom slučajnih uzoraka (Rowcliffe i sur., 2013.). Osim toga, ukoliko se podaci obrađuju prema početlu poznatih jedinki tada je temeljna pretpostavka da su jedinke u prostoru dispergirane neovisno te da svaka koristi definirani životni prostor.

Prema istraživanjima Jenks i sur. (2011.) kamere u prosjeku prije detektiraju mesoždere nego biljoždere (*Slika 32.*).



Slika 32. Vrijeme proteklo do prve detekcije mesoždera i ostalih trofičkih skupina s obzirom na broj postavljenih kamera. Izvor: Jenks i sur., 2011.; 119 p.

5.2. NAČIN POSTAVLJANJA KAMERA I UTJECAJ POLOŽAJA KAMERE NA REZULTATE PRAĆENJA DIVLJAČI

Prema Acrenac i sur. (2012.) kamere je najbolje postavljati nisko (30 do 40 cm od tla), no to ovisi i o vrsti koju istražujemo. Sitnije vrste kamere neće zabilježiti ako su postavljene na većim visinama. Kada god je moguće kamere treba postavljati na zaravnjen teren, a ukoliko to nije moguće tada se kamere postavljaju pod kutem tako da slikaju paralelno s tlom. Nadalje, kamere bi od mjesta gdje životinje prolaze (premet) trebale biti udaljene oko 3 m. Ukoliko se snimljene životinje želi identificirati tada je najbolje postaviti dvije kamere koje se dogledaju. Glede strana svijeta najbolje ih je postaviti prema sjeveru (McCoy i sur., 2011.).

U svom priručniku za praćenje divljih životinja pomoću kamera Gillespie i sur. (2015.) savjetuju da se ispred kamere postavljaju mamci s hranom kako bi vjerojatnost detekcije bila viša. Međutim, pojedini rezultati istraživanja (Jacobson i sur., 1997.; Larruea i sur., 2007.) navode kako prilikom primamljivanja jelena hranom sve jedinice ne koriste

hranilište istom učestalošću. Stoga je i različita vjerojatnost uočavanja određenih dobnih i spolnih skupina što dovodi do pogrešne procjene strukture populacije.

McCoy i sur. (2011.) su u zatvorenom lovištu od 258 ha testirali razliku u detektiranju pojedinih dobnih i spolnih skupina bjelorepog jelena (*Odocoileus virginianus*), a kamere su imale odgodu snimanja 30 sekundi i 5 minuta. Istraživanje je trajalo od 11. rujna 2008. do 5. ožujka 2009. (razdoblje prije parenja i parenje⁴) u 3 tretmana – kamere su postavljene na slučajne lokacije, na premete i na hranilišta, a udio snimljenih životinja je bio sljedeće:

- ✓ 75,3 % na hranilištima,
- ✓ 16,0 % na premetima i
- ✓ 8,7 % na slučajnim pozicijama.

Tijekom jeseni je udio teladi snimljenih na slučajnim pozicijama 3.1 puta viši nego na hranilištima, dok je tijekom razdoblja parenja najmanje adultnih mužjaka snimljeno na hranilištima. To je i logično jer se teljenje bjelorepog jelena odvija u kolovozu pa land u jesen još uvijek nije dovoljno pokretna, dok tijekom parenja mužjaci uzimanju manje hrane pa slabo posjećuju hranilišta. Stoga, ako se prebrojavanje bazira na snimkama iz tog razdoblja može doći do podcjenjivanja brojnosti i pogreške kod izračuna omjera spolova. Tijekom istraživanog razdoblja pojavnost košuta se nije značajnije razlikovala bez obzira na mjesto snimanja. Temeljna pretpostavka je kako se na hranilištima kamerama ne mogu dobiti pouzdani podaci o strukturi i brojnosti populacije (Koerth i Kroll, 2000.). No McCoy i sur. (2011.) su dokazali kako u slučaju da se kamere postavljaju na hranilištima jedino nisu pouzdani podaci za telad tijekom jeseni. Generalno, pouzdanost podataka dobivenih tom metodom ovisi i o pretpostavci da je stopa aktivnosti ista za sve dobne i spolne razrede što je pogrešno. Tako je lanad slabo aktivna pa se njena brojnost podcijeni, dok stopa mobilnosti adultnih jelena tijekom parenja naraste za 27 %.

Udio podcijenjenih jedinki može biti uzrokovan i značajkama kamere. Tako su Gregersen i Gregersen (2014.) podcijenili brojnost tetrijeba ruševca (*Lyrurus tetrix*) na bojinama jer im korišteni modeli kamere nisu bile u mogućnosti snimati dok količina svjetlosti nije prešla 12,5 luxa; a jačina svjetlosti civilnog sumraka je na mjestu praćenja iznosila 3,4 luksa. Prijašnja inventarizacija osmatranjem je pokazala da brojači (ljudi) i pri takvoj smanjenoj vidljivosti jasno uočavaju ruševca tako da je greška nastala prebrojavanjem

⁴ na ovome se području parenje bjelorepog jelena odvija u siječnju.

osmatranjem manja. No, s druge strane kamere su zabilježile kako pijevci na bojinama borave cijelu godinu kako bi se izborili za hijerarhijski položaj u jatuu, a ne samo za hareme. Pri tome su vrhunci borbi na bojinama u svibnju te u listopadu, kada pijevci-godišnjaci postaju spolno zreli.

Prilikom istraživanja dinamike aktivnosti jazavca (*Meles meles*) Rachova i sur. (2012.) su kod korištenog modela kamere Moultrie Game Spy dobili različit udio praznih snimaka, ovisno o tome gdje je kamera bila postavljena. Tako je u nizinskom području Bugarske udio praznih snimaka iznosio 30 %, a u gorskom području (1 550 m nadmorske visine) udio praznih snimaka bio 46 %. Razlog većeg udjela praznih snimaka u gorju su oštriji vremenski uvjeti (snijeg, kiša, vjetar) koji su aktivirali kameru. Oni su aktivnost jazavca računali s obzirom na udio snimaka na određenoj lokaciji i u određenom vremenu u ukupnim snimcima. Prema njima i u nizini i u gorju jazavci 40 do 50 % vremena provode uz samu jazbinu, no vrhunac zadržavanja jazavca uz jazbinu u nizinskom području pada zimi, a u gorju tijekom proljeća.

5.3. UTJECAJ POJEDINIH OKOLIŠNIH ČIMBENIKA NA PONAŠANJE ŽIVOTINJA

U lovačkim krugovima je uvriježeno (tradicionalno) mišljenje da mjesečeve mijene te položaj Mjeseca na nebu utječe na aktivnost divljači. Tako je John Alden Knight (Knight, 1942.) u svojoj knjizi sugerirao da aktivnost životinja raste kako odmiče razdoblje pojave Mjeseca (izlazak Mjeseca, zalazak Mjeseca, ponoć, podne) te je nastala tzv. solunarna teorija (iako je ona nastala još 1935., Popović, 1956.). Prema toj teoriji ptice, sisavci i ribe se kreću u skladu s odnosom položaja Mjeseca i njihova tijela. Prema Knight (1942.) Aktivnost životinja je najviša u fazi kada je Mjesec na najvišoj (ponoć) i najnižoj točki (podne), a najmanja u fazama mjesečeva izlaska i zalaska. Na temelju toga je izradio tzv. solunarne karte, u kojima je, ovisno o mjesečevim mijenama, svaki dan rangiran od 1 do 4, pri čemu rang 4 ukazuje na maksimalnu predikciju ponašanja jelena. Ova se teorija dosta ukorijenila među ribolovcima i ribarima, a kod lovaca nešto manje. Roseberry i Wolf (1986.) su pokušali istražiti ovu pojavu te zaključuju kako nema povezanosti između solunarnog razdoblja i aktivnosti divljači. No, oni su istraživanje vršili izravnim osmatranjem divljih životinja. Povezanost aktivnosti životinja s mjesečevim mjenama je i kasnije istraživana, ali u relativno malom obujmu. Tako

se zna da štakor skakač (*Dipodomys spectabilis*; Daly i sur., 1992.), američki bijeli zec (*Lepus americanus*; Griffin i sur., 2005.) smanjuju noćnu aktivnost tijekom jako osvijetljenih noći (razdoblje punog Mjeseca) kako bi se što manje izložili predatorima. To ne znači da potencijalni plijen tijekom uštapa ne pokazuje aktivnost nego reducira konzumaciju krmiva, hrani se kraće vrijeme, dulje se zadržava u zatvorenom staništu (gusta vegetacija), a isto tako smanjuje veličinu prostora na kojem se hrani.

Budući da je time količina potencijalnog plijena u staništu smanjena predatori također snižavaju aktivnost, kao npr. grivasti vuk (*Chrysocyon brachyurus*; Sabato, 2006.). Na individualnoj razini, lisica tijekom prolaska različitih mjesečevih mijena preferira različit plijen (Molsher i sur., 2000.).

Rachova i sur. (2012.) su aktivnost jazavca povezivali s mjesečevim ciklusom od 8 faza, a ne od 4 faze. Tijekom lunarnog ciklusa postoje 2 vrhunca aktivnosti jazavca – neposredno prije (faza 4 - rastuće ispučen) i neposredno poslije punog Mjeseca (faza 6 – padajuće ispučen). Vrhunac aktivnosti na oba lokaliteta je bio od 19 do 21 sat. Pri čemu je u gorju imao još jedan manji vrhunac od 3 do 5 sati. Glede temperature zraka vrhunac aktivnosti jazavca je bio pri temperaturi od -3 do -1 °C (gorje), odnosno od 1 do 3 °C (nizinsko područje). Praćenje je pokazalo da se osim ranog proljeća parenje može dogoditi i u studenome.

Iako je uvriježeno mišljenje da je ris noćna ili sumračna životinja, treba istaknuti kako su njegove oči u odnosu na oči noćnih mačaka proporcionalno manje te nešto lošije prilagođene uvjetima smanjenog svijetla. Stoga glavnina kretanja, odnosno aktivnosti crvenog risa (*Lynx rufus*) vrhuni tijekom jutarnjeg i večernjeg sumraka (153 m/h) i tijekom dana (144 m/h) a najniža je tijekom mračnog razdoblja u kojem nema mjesečine (120m/h; Rockhill i sur., 2013.). Pri tome sitan plijen pokazuje najvišu stopu aktivnosti pri iluminaciji od 10 do 49 %, što predstavlja i optimum noćnog lova za crvenog risa. Tijekom mladog Mjeseca stopa kretanja crvenog risa je najniža tijekom noći, ali je najviša tijekom dana (80 m/h). Tijekom razdoblja uštapa situacija je obrnuta. Same mjesečeve mijene nisu najbolji pokazatelj aktivnosti životinje jer je nazočna vrlo visoka varijabilnost u osvjetljenju. Naime, ona ovisi o kutu Mjeseca te o intenzitetu naoblake, ali isto tako i o tipu staništa. Treba imati na umu kako se plijen pri dobrom osvjetljenju i na otvorenom staništu nerado kreće jer se izlaže predaciji, ali isto tako i lakše uoči predatora. U tim ekstremnim uvjetima se i predator i plijen sele u zatvorenija staništa. Stoga je bolji prediktor temperatura zraka. Naime ris se signifikantno više giba pri temperaturama zraka preko 15 °C. Generalno, prema Rockhill i sur. (2013.) struktura

staništa predstavlja 3. dimenziju u razumijevanju aktivnosti životinja. Prva dimenzija bi bila temperatura, druga dinamika populacije, a četvrta količina osvjetljenja.


U novije vrijeme je ova povezanost istražena i na bjelorepom jelenu (Sullivan i sur., 2016.). Prema njima, tijekom razdoblja mlađaka i uštapa tijekom izlaska i zalaska Mjeseca aktivnost bjelorepog jelena raste, a prije razdoblje mlađaka i uštapa tijekom ponoći i podneva aktivnost jelena pada. Ovo se ne poklapa s prognozama solunarnih karata jer je vrhunac aktivnosti obrnut (najveći je tijekom izlaska i zalaska Mjeseca za vrijeme mlađaka i uštapa, a ne tijekom podneva i ponoći). Međutim, većina istraživanja aktivnosti jelenske divljači je rađena u područjima u kojima su cervidi bili izloženi visokom lovnom pritisku (osobito u Europi), a nije bilo krupnih predatora. Studije rađene početkom 21. stoljeća na području Sjeverne Amerike pokazale su kako vukovi imaju jak utjecaj na ponašanje vapitija (*Cervus elaphus nelsoni*), a osobito glede opreza, načina kretanja i odabira krmiva.

Dok Woodside (2010.) navodi kako mjesečeve mijene (osobito u fazi uštapa i mlađaka) nemaju značajan utjecaj na ponašanje vapitija, u na području Spačve Prebanić (2014.) ukazuje kako je aktivnost jelena običnog (*Cervus elaphus*) tijekom rike povišena u fazi zadnje četvrti, a najniža u fazi uštapa. Ovime jelen pokazuje sličan ritam aktivnosti kao i srneća divljač.

Kamler i sur. (2007.) su istraživali obrasce ponašanja jelena običnog u staništu s krupnim predatorom (vukom), ali bez ljudskih lovnih aktivnosti. Tijekom ljeta i jeseni aktivnost oba spola pokazuje nekoliko vrhunaca, no ona se kod oba spola različita. Jeleni su aktivniji tijekom dopodneva i u kasno poslije podne (od 16 do 17 sati), a košute tijekom rano jutarnjih sati i u večernji sumrak (suton). Tijekom zime nema razlike u aktivnosti između spolova. Najniža aktivnost je nešto prije svitanja (najhladniji dio dana), a najviša nešto prije zalaska Sunca (najtopliji dio dana). Generalno uz nazočnost krupnih predatora i izostanak lova po čovjeku jelenska divljač pokazuje krepuskularne vrhunce aktivnosti. Osim toga, dnevni ritam aktivnosti u tim uvjetima se poklapao s onim u europskog bizona (*Bison bonasus*; Cabo-Raczynska, 1983.; 1987.) te soba (*Rangifer tarandus*;). To je tzv. polifazna dnevna aktivnost tipična za preživače, a očituje se u izmjeni faze hranjenja i odmora (žvakanje i preživljanje). Iz ovoga proizlazi kako se predatori moraju prilagoditi na ritam aktivnosti biljoždera.

Osim na aktivnost životinja znanstvenici su pokušali istražiti utjecaj mjesečevih mijena i na dinamiku populacije. Tako je Archibald (1977.) povezao mjesečeve mijene i ciklus linije čvorova Mjeseca s dinamikom populacije kanadskog risa (*Lynx canadensis*),

američkog bijelog zeca i američke lještarke (*Bonasa umbellus*). Naime, ciklus linije čvorova Mjeseca urokuje znatne promjene u lunarnoj deklinaciji, vremenima izlaska i zalaska Sunca te u visini i vremenu javljanja klime, a traje 18,6 godina (Baker, 1959.). No, 10-godišnji populacijski ciklus kod terestričkih vrsta životinja je generalno ograničen na borealne šume u pojasu iznad otprilike 45⁰ sjeverne geografske širine.



Slika 33. Dnevni obrazac aktivnosti srne obične u sjeveroistočnim Apeninima. Isprekidane i pune crte označavaju zoru i suton.

Izvor: Pagon i sur., 2013.; 779 p.


Prema Ashov (1954.) sekvenca dana i noći (cirkadijan) je dominantan davatelj vremenskih impulsa, koji sinhroniziraju unutarnji sat većine terestričkih organizama. No, ovaj se cirkadijalan obrazac ponašanja može promijeniti, kao što se mijenjaju i vremenski uvjeti (godišnje doba, vremenske prilike, socijalne i individualne značajke, izbjegavanje predatora, čovjeka ili dostupnost hrane). Cirkadijalni sat je neizostavna evolucijska pojava koja organizmima pospješuje korištenje dijela dana i sezone, s time da biokemijske, fiziološke i etološke procese moraju uskladiti s vanjskim promjenama (Yerushalemi i Green, 2009.). U umjerenim zonama dnevna fotoperioda i termoperioda znatno variraju među godišnjim dobima. Stoga ove promjene imaju znatan utjecaj varijabilnost u fiziologiji i ponašanju životinja (Sumova i sur., 2004.; van Oort i sur., 2007.), a dosta su vezani i na geografsku širinu (što je dokazano i kod soba – van Oort i sur., 2005., ali ne i kod euroazijskog risa koji je zvijer – Heurich i sur., 2014.).

Telemetrijska ponašanja istraživanja srneće divljači u umjerenj zoni (Pagan i

sur., 2013.) su pokazala kako ona ima dva jasno odvojena vrhunca aktivnosti – u zoru i u suton bez obzira na godišnje doba (*Slika 33.*). Razmak ovih vrhunaca je najveći ljeti (14 sati), a najmanji zimi (9 sati) što je posljedica promjene u fotoperiodi. Pri tome mjesečeve mjene nemaju značajan utjecaj na noćnu aktivnost srneće divljači, ali zato statistički značajan utjecaj imaju:

- ✓ spol – srnjaci su noću aktivniji ($33,69 \% \pm 0,76 \%^5$) od ženki ($28,97 \% \pm 0,59 \%$);
- ✓ razdoblje lovidbe i lovostaje – tijekom razdoblja lovidbe su grla manje aktivna ($35,70 \% \pm 0,57 \%$) nego tijekom lovostaje ($38,30 \% \pm 0,38 \%$);
- ✓ temperatura zraka – što je temperatura zraka višlja to je viša i aktivnost.

Općenito se smatra kako je cirkadijalan ritam mačaka sumračan ili noćan, iako su mačke glede anatomske strukture oka dobro prilagođene svim svjetlosnim prilikama (Sunquist i Sunquist, 2002.), što vrijedi i za euroazijskog risa (*Lynx lynx*). Dosadašnja istraživanja su pokazala kako su reproduktivne ženke noću manje aktivne nego adultni mužjaci, no općenit obrazac aktivnosti se kod oba spola ne mijena. Pri tome su mužjaci tijekom razdoblja reprodukcije aktivniji i imaju veći životni prostor. No, zanimljivo je kako ova vrsta pokazuje vrlo sličan obrazac ponašanja kao i srneća divljač (Heurich i sur., 2014.), što i objašnjava da mu je srneća divljač naučestaliji plijen (Kotorac, 2010.).



Slika 34. Aktogram dnevne aktivnosti srnjaka (lijevo) i srne (desno) u sjeveroristočnom dijelu Apenina (rujan 2008. – ožujak 2010.). Izvor: Pagon i sur., 2013.; 780 p.

⁵ Aktivnost se iskazuje kao postotak vremena unutar jednog sata u kome je jedinka bila aktivna.

U suvremenim istaživanjima u prikazivanju obrazaca aktivnosti divljih životinja sve učestalije se koriste tzv. aktogrami. Oni prikazuju skupne vrijednosti za sve istraživane jedinke te daju dobar prikaz varijabilnosti ili ujednačenosti obrasca aktivnosti (npr. Pagon i sur., 2013.). Na aktogramu vertikalne crte predstavljaju razine aktivnosti unutar jednog sata. Visina crnih stupaca je funkcija razine aktivnosti. Pri tome izostanak crnih crta (bijele šupljine) označava da je aktivnost po satu bila 0 %, a što se aktivnost približava 100 % udjela aktivnosti po satu to su crni stupci viši. Na *Slici 34.* je prikazana aktivnost dvaju grla srneće divljači (lijevo je srnjaka, a desno srna). Sive okomite crte predstavljaju zoru i suton, prema civilnom vremenu.

Iako je u istraživanju korištena samo jedna kamera na jednoj poziciji, ona je bila aktivna dulje od jedne kalendarske godine (586 dana, 19 sati i 26 minuta), odnosno pratila je divljač tijekom svih mjeseci, bez obzira što je tijekom razdoblja travanj – lipanja bila najmanje aktivna. U većini istraživanja, čiji su rezultati navedeni u ovome diplomskome radu, bez obzira radi li se o tehnici praćenja divljih životinja foto klopama ili telemetrijskim praćenja je trajalo daleko kraće (često svega nekoliko mjeseci). Stoga podaci dobiveni na lokalitetu Rov pružaju relativno pouzdani oslonac u poznavanju cirkadijarnog ponašanja srne obične, divlje svinje, lisice i jazavca, no u slučaju ove posljednje dvije vrste, kameru bi ipak trebalo smjestiti ispred njihovih nastambi. Generalno, čak ni to neće osigurati 100 %-tnu detekciju lisice i jazavca jer jedna nastamba može imati i do 20 otvora (Krapinec i sur., 2015.), no glede predviđanja razdoblja hvatanja divlje svinje (ciljano hvatanje i označavanje prasadi) najbolji termin je razdoblje ožujak-kolovoz.

6. ZAKLJUČCI

Na temelju provedenog istraživanja može se zaključiti slijedeće:

1. Vrijednosti RAI-a pokazuju relativno veliku godišnju dinamiku. Kod ženki srneće divljači broj snimljenih jedinki je kulminirao od studenog do ožujka (RAI od 95 do 190). RAI srnjaka pokazuje dva vrhunca – ožujak (RAI=161) i studeni (RAI=103). Vrhunac brojnosti divlje svinje u predjelu praćenja je bio tijekom srpnja (RAI=31) i kolovoza (RAI=34), no u odnosu na srneću divljač indeks njene brojnosti je znatno niži. Lisica je najučestalije bila detektirana u ožujku (RAI=48), a jazavac u travnju (RAI=45) i svibnju (RAI=39). Utvrđeno je kako se pojavnost divljači na snimkama slaže sa njihovim godišnjim ritmom aktivnosti.
2. Godišnja aktivnost srneće divljači pokazuje dva maksimuma . Prvi je maksimum u ožujku, a drugi u studenome, dok je od svibnja do srpnja ta aktivnost najmanja. Srneća je divljač veći dio godine najaktivnija noću, a nakon toga tijekom sumraka, dok aktivnost tijekom svijetlog dijela dana ne pokazuje značajne oscilacije i vrlo je mala. Aktivnost divlje svinje kulminira od ožujka do kolovoza te se generalno može uočiti kako je ona, za razliku od srne obične uglavnom noćna životinja. Lisica pokazuje maksimum aktivnosti od studenog do travnja, a povremena aktivnost je zabilježena od srpnja do rujna. Vrhunac aktivnosti jazavca se jasno može uočiti tijekom travnja i svibnja te je njegova aktivnost gotovo isključivo vezana za noć.
3. Kod srneće divljači najviša aktivnost je zabilježena tijekom faza padajuće ispupčenog Mjeseca, mlađaka, padajuće srpolikog Mjeseca i zadnje četvrti, a najmanje je aktivna u fazi uštapa (punog Mjeseca). Srneća divljač najmanje je aktivna u rujnu (najjasnija distribucija). Divlja svinja najvišu noćnu aktivnost također pokazuje tijekom razdoblja mladog Mjeseca, a nakon toga u vrijeme uštapa pa u vrijeme rastuće ispupčenog Mjeseca, zadnje četvrti i padajuće srpolikog Mjeseca. Lisica pokazuje razmjerno najvišu noćnu aktivnost u vrijeme padajuće srpolikog Mjeseca, a najmanju u fazi rastuće srpolikog Mjeseca (faza 2), dok jazavac najnižu stopu aktivnosti pokazuje u fazi 1 (mlađak) i 2 (rastuće srpoliki Mjesec).
4. Srneća divljač aktivna je pri dosta visokim temperaturama (u kolovozu i do 32 °C) kao i pri nižim temperaturama (u siječnju do -10 °C). No, tijekom najnižih temperatura zraka (zimski mjeseci) aktivnosti srne su bile najviše i obrnuto (tijekom ljetnih mjeseci je aktivnost najniža). Kod divlje svinje je uočena najviša razina aktivnosti pri višim temperaturama zraka (travanj-rujan), a s obzirom na razliku između sumračnih i noćnih temperatura ne može se uočiti neka povezanost. Lisica je općenito aktivnija pri nižim temperaturama dok je u hladnijem dijelu godine češće zabilježena tijekom sumraka nego tijekom noći. Kod jazavca nema neke povezanosti između temperature i aktivnosti.

7. LITERATURA

1. Ancrenaz, Hearn, A. J.; Ross, J.; Sollmann, R.; Wilting, A., 2012: Handbook for wildlife monitoring using camera-traps. BBEC II Secretariat, c/o Natural Resources Office, Sabah, Malaysia. URL: <https://www.bbec.sabah.gov.my>, 71 pp.
2. Archibald H. L., 1977: Is the 10-Year Wildlife Cycle Induced by a Lunar Cycle? *Wildlife Society Bulletin*, 5(3): 126-129.
3. Aschoff, J., 1954: Zeitgeber der tierischen Tagesperiodik. *Naturwissenschaften* 41: 49–56.
4. Baker, R. H., 1959: *Astronomy*, 7th edition. Van Nostrand, Princenton, New Jersey, 547 pp.
5. Caboń-Raczyńska, K.; Krasieńska, M.; Krasieński, Z., 1983: Behaviour and daily activity rhythms of European bison in winter. *Acta Theriologica* 28:273–299.
6. Caboń-Raczyńska, K.; Krasieńska, M.; Krasieński, Z.; Wójcik, J. 1987: Rhythm of daily activity and behavior of European bison in the Białowieża Forest in the period without snow cover. *Acta Theriologica* 32:335–372.
7. Carbone, C.; Christie, S.; Conforti, K.; Coulson, T.; Franklin, N.; Ginsberg, J. R.; Griffiths, M., 2001: The use of photographic rates to estimate densities of tigers and other cryptic mammals. *Animal Conservation*, 4(1): 75–79.
8. Cartar, R. v., Montgomerie, R. D., 1987: Day-to-day variation in nest attentiveness of White-rumped Sandpipers. *Condor* 89:252-260.
9. Clevenger, A. P.; Dorsey, B.; Barrueto, M.; Ford, A. T., 2013: Activity patterns of wildlife at crossing structures as measure of adaptability and performance. *Proceedings of the 2013 International Conference on Ecology and Transportation (ICOET 2013)*. http://www.icoet.net/icoet_2013.
10. Collier, B. A., S. S. Ditchkoff, J. B. Raglin, and J. M. Smith. 2007. Detection probability and sources of variation in white-tailed deer spotlight surveys. *Journal of Wildlife Management* 71:277–281.
11. Cox, W. A.; Pruett, M. S.; Benson, T. J.; Chiavacci, S. J.; Thompson, F. R. III, 2012: Development of camera technology for monitoring nests. 185-210 pp; in C. A. Ribic, F. R. Thompson III, and P. J. Pietz (ur.). *Video surveillance of nesting birds. Studies in Avian Biology* (no. 43), University of California Press, Berkeley, CA. <http://digitalcommons.unl.edu/usgsnpwrc/250>

12. Daly, M.; Behrends, P.R.; Wilson, M.I.; Jacobs, L.F., 1992: Behavioral modulation of predation risk, moonlight avoidance and crepuscular compensation in a nocturnal desert rodent, *Dipodomys merriami*. *Animal Behavior* 44:1–9.
13. Delaney, D. K.; Grubb, T. G.; Garcelon, D. K., 1998: An infrared camera system for monitoring diurnal and nocturnal raptors. *J Raptor Res.* 32(4): 290-296.
14. Dell Inc., 2015: Dell Statistica (data analysis software system), version 12. software.dell.com.
15. Gardner, B.; Reppucci, J.; Lucherini, M.; Royle, J. A., 2010: Spatially explicit inference for open populations: estimating demographic parameters from camera-trap studies. *Ecology*, 91 (11): 3376–3383.
16. Gilbert, W. M.; Nolan, P. M.; Stoehr, A. M.; Hill, G. E., 2005: Filial cannibalism at a House Finch nest. *Wilson Bulletin* 117:413-415.
17. Gillespie, G. R.; Brennan, K.; Gentles, T.; Hill, B.; Low Choy, J.; Mahney, T.; Stevens, A.; Stokeld, D., 2015: A guide for the use of remote cameras for wildlife survey in northern Australia. Darwin: Charles Darwin University. 54 pp. <http://www.nespnorthern.edu.au/wp-content/uploads>.
18. Gompper, M.E.; Kays R.W.; Ray J.C., 2006: A comparison of noninvasive techniques to survey carnivore communities in northeastern North America. *Wildl. Soc. Bull.*, 34, 1142-1151.
19. Gregersen, H.; Gregersen, F., 2014: Wildlife cameras affectively survey Black Grouse *Lyrurus tetrix* leks. *Ornis Norvegica* 37: 1-6.
20. Griffin, P.C.; Griffin, S.C.; Waroquiers, C.; Mills, L.S., 2005: Mortality by moonlight: predation risk and the snowshoe hare. *Behavioral Ecology* 16:938–944.
21. Guzy, M. J.; Ribic, C. A.; Sample, D. W., 2002: Helping at a Henslow's Sparrow nest in Wisconsin. *Wilson Bulletin* 114:407-409.
22. Hespeler, B.; Krewer, B., 2003: Jung oder Alt? Schalenwild Richtig Ansprechen. BLV Verlagsgesellschaft München, 128 pp.
23. Heurich, M.; Hilger, A.; Küchenhoff, H.; Andrén, H.; Bufka, L.; Krofel, M.; Mattisson, J.; Odden, J.; Persson, J.; Rauset, G. R.; Schmidt, K.; Linnell, J. D. C., 2014: Activity Patterns of Eurasian Lynx Are Modulated by Light Regime and Individual Traits over a Wide Latitudinal Range. *PLoS ONE* 9(12): e114143. doi:10.1371/journal.pone.0114143.
24. http://aa.usno.navy.mil/faq/docs/moon_phases.php
25. http://astrogeo.geoinfo.geof.hr/online_efemeride/sunrise_sunset/
26. <http://www.elfiportablesecurity.com>

27. https://en.wikipedia.org/wiki/Lunar_phase
28. Hugson, D. L.; Darby, N. W.; Dungan, J. D., 2010: Comparison of motion-activated cameras for wildlife investigations. *California Fish and Game* 96(2): 101-109.
29. Jacobson, H. A.; Kroll, J. C.; Browning, R. W.; Koerth, B. H.; Conway, M. H. 1997: Infrared-triggered cameras for censusing white-tailed deer. *Wildlife Society Bulletin* 25:547–556.
30. Jenks, K. E.; Chanteap, R.; Damrongchainarong, K.; Cutter, P.; Cutter, P.; Redford, T.; Lynam, A. J.; Hovard, J.G.; Leimgruber, P., 2011: Using relative abundance indices from camera-trapping to test wildlife conservation hypotheses – an example from KhaoYai National Park, Thailand. *Mongabay.com Open Access Journal – Tropical Conservation Science*, 4(2): 113-131.
31. Kamler, J. F.; Jędrzejewska, B.; Jędrzejewski, W., 2007: Activity patterns of red deer in Białowieża National park, Poland. *Journal of Mammalogy*, 88(2): 508-514.
32. Karanth, K. U.; Nichols, J. D.; Kumar, N. S.; Hines, J. E. 2006: Assessing tiger population dynamics using photographic capture-recapture sampling. *Ecology*, 87 (11): 2925–2937.
33. Knight, J. A. 1942. *Moon up moon down*. Charles Scribner's Sons, New York, New York.
34. Koerth, B. H., C. D. McKown, and J. C. Kroll. 1997. Infrared-triggered camera versus helicopter counts of white-tailed deer. *Wildlife Society Bulletin* 25:557–562.
35. Koerth, B. H.; Kroll, J. C., 2000: Bait type and timing for deer counts using cameras triggered by infrared monitors. *Wildlife Society Bulletin* 28:630–635.
36. Konjević, D.; Krapinec, K., 2014: Periodičko zajedničko izvješće. Projekti: 1. Zdravlje divljači i zoonotski potencijal na području Parka prirode Medvednica – Grad Zagreb. 2. Primijenjena istraživanja divljači na području parka prirode „Medvednica“ – Grad Zagreb. Zagreb, 57 pp.
37. Kotorac, T., 2010: Ekološke i populacijske značajke Euroazijskog risa (*Lynx lynx* L.). Završni rad, Sveučilište u Zagrebu Šumarski fakultet, 37 pp.
38. Krapinec, K., 2010: Program zaštite divljači za dio Parka prirode "Medvednica" - Grad Zagreb, za razdoblje 2010./2011.-2019./2020. Grad Zagreb, Gradski ured za poljoprivredu i šumarstvo, Zagreb, 165 pp.
39. Krapinec, K.; Kotorac, T.; Konjević, D.; G., E. 2015: Prostorni raspored i značajke lisičjih nastambi na južnom dijelu Parka prirode "Medvednica". 50. hrvatski i 10. međunarodni simpozij agronoma- Proceedings / Milan Pospíšil (ur.). Zagreb : Sveučilište u Zagrebu, Agronomski fakultet, Zagreb, Hrvatska, 384-388.

40. Larrucea, E. S.; Brussard, P. F.; Jaeger, M. M.; Barrett, R. H. 2007: Cameras, coyotes, and the assumption of equal detectability. *Journal of Wildlife Management* 71:1682–1689.
41. Magdić, M.; Barišić, I.; Jelušić, P. B., 2014: Time-lapse fotografija. Seminarski rad, Katedra za grafičkidizajn i slikovne informacije Grafički fakultet Sveučilišta u Zagrebu, 11 pp.
42. Marshal, J. P.; Krausman, P. R.; Bleich, V. C. 2008: Body condition of mule deer in the Sonoran Desert is related to rainfall. *Southwestern Naturalist* 53:311-318.
43. McCoy, J. C.; Ditchkoff, S. S.; Steury, T. D., 2011: Bias Associated With Baited Camera Sites for Assessing Population Characteristics of Deer. *Journal of Wildlife Management*, 75(2): 472-477; DOI: 10.1002/jwmg.54.
44. Molsher, R.L.; Gifford, E.J.; McIlroy, J.C., 2000: Temporal, spatial and individual variation in the diet of red foxes (*Vulpes vulpes*) in central New South Wales. *Wildlife Research* 27: 593–601.
45. Mooty, J. J., and P. D. Karns. 1984. The relationship between white-tailed deer track counts and pellet-group surveys. *Journal of Wildlife Management* 48:275–279.
46. Nakamura J., 2006: Image sensors and signal processing for digital still cameras. Taylor & Francis Group, Boca Raton FL, 321 pp.
47. Nathan, A;Legge, S.; Cockburn, A. 2001: Nestlingaggression in broods of a siblicidal kingfisher, theLaughing Kookaburra. *Behavioral Ecology* 12:716-725.
48. O'Brien, T. G.; Kinnaird, M. F.; Wibisono, H. T., 2003: Crouching tigers, hidden prey: Sumatran tiger and prey populations in a tropical forest landscape. *Animal Conservation*, 6 (2): 131–139.
49. O'Connell, A. F.; Nichols, J. D.; Ullas Karanth, K., 2011: Camera traps in Animal Ecology: Methods and Analyses. 1st ed. Springer, Tokyo Dordrecht Heidelberg London New York, 271 pp.
50. Otani, T., 2001: Measuring fig foraging frequency of the Yakushima macaque by using automatic cameras. *Ecological Research* 16:49-54.
51. Otani, T., 2002: Seed dispersal by Japanese marten *Martes melampus* in the subalpine shrubland of northern Japan. *Ecological Research* 17:29-38.
52. Pagon, N.; Grignolio, S.; Pipia, A.; Bongi, P.; Bertolucci, C.; Apollonio, M., 2013: Seasonal variation of activity patterns in roe deer in a temperate forested area. *Chronobiology International* 30(6): 772–785.
53. Pietz, P. J., Granfors,D. A., 2000: Identifyingpredators and fates of grassland passerine nestsusing miniature video cameras. *Journal of WildlifeManagement* 64:71-87.

54. Plhal R., Kamler J., Homolka M. i Adamec Z. (2011.): An assessment of the applicability of photo trapping to estimate wild boar population density in a forest environment. *Folia Zoologica* 60: 237-246.
55. Popović, Lj., 1956: Solunarna teorija. *Ribarstvo* 11(1): 15-16.
56. Prebanić, I., 2014: Analiza dnevne i sezone aktivnosti jelena običnog (*Cervus elaphus* L.) na području državnog lovišta XVI/1 "Spačva". Rad nagrađen rektorovom nagradom. Sveučilište u Zagrebu, Šumarski Fakultet, Zagreb, 33 pp.
57. Racheva, V.; Zlatanova, D.; Peshev, D.; Markova, E., 2012: Camera Traps Recorded Use of Sett Sites by Badgers (*Meles meles* L., Mammalia) in Different Habitats. *Acta zool. bulg.*, 64(2): 145-150.
58. Rockhill, A. P.; DePerno, Ch. S.; Powell, R. A., 2013: The Effect of Illumination and Time of Day on Movements of Bobcats (*Lynx rufus*). *PLoS ONE* 8(7): e69213. doi:10.1371/journal.pone.0069213.
59. Roša, D.; Valečić, A.; Drvar, Z.; Hržina, D.; Romštajn, I.; Maričić, D.; Bašić, M., 2016: *Astronomija 1 – web izdanje. Zvezdarnica Zagreb – Zagrebački astronomski savez. Zagreb, 156 pp.*
60. Rowcliffe, J. M.; Field, J.; Turvey, S. T.; Carbone, Ch., 2008: Estimating animal density using camera traps without the need for individual recognition. *Journal of Applied Ecology*, 45: 1228-1236. doi: 10.1111/j.1365-2664.2008.01473.x
61. Rowcliffe, J. M.; Jansen, P. A.; Kays, R.; Kranstauber, B.; Carbone, Ch., 2016: Wildlife speed cameras: measuring animal travel speed and day range using camera traps. *Remote Sensing in Ecology and Conservation* 2(2): 84-94. doi: 10.1002/rse2.17.
62. Rowcliffe, J.M.; Carbone, Ch.; Jansen, P. A.; Kays, R.; Kranstauber, B., 2011: Quantifying the sensitivity of camera traps: an adapted distance sampling approach. *Methods Ecol. Evol.*, 2, 464-476.
63. Rowcliffe, J.M.; Kays, R.; Carbone, C.; Jansen, P.A., 2013: Clarifying assumptions behind the estimation of animal density from camera trap rates. *J. Wildl. Manage.*, 77: 876.
64. Royle, J. A., Nichols, J. D. 2003: Estimating abundance from repeated presence-absence data or pointcounts. *Ecology*, 84 (3): 777–790.
65. Sabato, M.A.L.; de Melo, L.F.B.; Magni, E.M.V.; Young, R.J.; Coelho, C.M., 2006: A note on the effect of the full moon on the activity of wild maned wolves, *Chrysocyon brachyurus*. *Behavioral Processes* 73:228–230.

66. Spittler, H., 1995: Ein Beitrag zur Art und Menge der Beute während der Jungenaufzucht beim Sperber (*Accipiter nisus nisus* L.). Zeitschrift für Jagdwissenschaft 41 (3): 188-197.
67. Šprem N., Fabijanić N., Protrka K., Popović Z., Bulić A. i Šabić B. (2011.): Primjenasenzornih kamera u procjeni gustoće populacije divokoze u Parku prirode Biokovo. Journal of Central European Agriculture 12, str. 576-577.
68. Sullivan, J. D.; Ditchkoff, S. S.; Collier, B. A.; Ruth, Ch. R.; Raglin, J. B., 2016: Movement with the Moon: White-tailed Deer Activity and Solunar Events. Journal of the Southeastern Association of Fish and Wildlife Agencies, 3: 225-232.
69. Sunquist, M.E.; Sunquist, F.; 2002: Wild cats of the world: University of Chicago Press. 240 pp.
70. Sutherland, W. J., 2006: Ecological Census Techniques: a handbook, Second edition. Cambridge University Press, The Edinburgh Building, Cambridge, 432 pp.
71. Tomljanović, K.; Grubešić, M.; Krapinec, K., 2010: Testiranje primjenjivosti digitalnih senzornih kamera za praćenje divljači i ostalih životinjskih vrsta. Šumarski list 134(5-6): 287-292.
72. Trolliet, Fr.; Huynen, M-C.; Vemeulen, C.; Hambuckers, A., 2014: Use of camera traps for wildlife studies. A review. Biotechnol. Agron. Soc. Environ. 18(3): 446-454.
73. van Oort, B.E.; Tyler, N.J.; Gerkema, M.P.; Folkow, L.; Blix. A.S.; Stokkan K.-A., 2005: Circadian organization in reindeer. Nature 438: 1095–1096.
74. van Oort, B.E.H.; Tyler, N.J.C.; Gerkema, M.P.; Folkow L.; Stokkan K.-A., 2007: Where clocks are redundant: weak circadian mechanisms in reindeer living under polar photic conditions. Naturwissenschaften, 94: 183–94.
75. Woodside, G. J., 2010: Rocky Mountain Elk (*Cervus elaphus nelsoni*) Behavior and Movement in Relation to Lunar Phases, Master thesis, Oregon State University, Oregon, 37 pp.
76. Yerushalmi, S.; Green, R.M., 2009: Evidence for the adaptive significance of circadian rhythms. Ecol Lett, 12: 970–81.